

WALMOR CARDOSO GODOI

**DETECÇÃO DE DEFEITOS EM ISOLADORES POLIMÉRICOS POR  
RADIOGRAFIA DIGITAL**

Dissertação apresentada como requisito parcial à  
obtenção do grau de Mestre em Engenharia, Pro-  
grama de Pós-Graduação em Engenharia, Universi-  
dade Federal do Paraná.

Orientador: Dr. Vitoldo Swinka Filho

Co-orientador: Dr. Romeu Ricardo da Silva

CURITIBA

2005

*Dedico este trabalho:*

*Aos meus pais, Pedro e Shirley.*

*Aos amigos que, hoje, vivem somente em minhas lembranças.*

## AGRADECIMENTOS

Ao meu orientador, Prof. Dr. Vitoldo Swinka Filho, pelos ensinamentos, sugestões, conselhos, amizade e principalmente por acreditar na minha vontade de trabalhar com algo tão novo para mim.

Ao meu co-orientador, Dr. Romeu Ricardo da Silva, que através de suas orientações *online* sempre pode me apoiar, fazer sugestões, discutir, mas principalmente pela paciência em me ensinar as “redes”.

Ao Prof. Dr. Renê Robert, pelo incentivo, apoio e discussões.

Ao Prof. Dr. Helio Pedrini do Departamento de Informática da Universidade Federal do Paraná pelo apoio, discussões e sugestões.

Aos colegas Nilton Sergio Ramos Quoirin, pelas discussões e pela ajuda com a instrumentação eletrônica do *setup* de controle do SISTEMA RDP e pela ajuda na programação inicial em MATLAB; Wilson José da Silva pela ajuda com a instrumentação eletrônica do *setup* de controle do SISTEMA RDP; Eduardo Massahiko Higashi pela ajuda com a instrumentação eletrônica e apoio; Bruno Nahuili Bressan pelo apoio e por algumas fotos que estão presentes nesta dissertação; Sebastião Ribeiro Junior, pelo apoio.

À Elizete Pires, secretária do Programa de Pós - Graduação em Engenharia da Universidade Federal do Paraná.

À Universidade Federal do Paraná.

Ao Instituto de Tecnologia para o Desenvolvimento - LACTEC.

À Companhia Paranaense de Energia - COPEL, pelo auxílio financeiro concedido.

Aos amigos, Arnoldo Brasílio Filho e Edson Luis da Silva.

A todos aqueles que de uma forma ou outra contribuíram para esse trabalho.

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>2</b>	<b>PRINCÍPIOS DE RADIOGRAFIA</b>	<b>4</b>
2.1	O FÓTON . . . . .	4
2.2	O EFEITO FOTOELÉTRICO . . . . .	4
2.3	O EFEITO COMPTON . . . . .	6
2.4	PRODUÇÃO DE RAIOS X . . . . .	6
2.5	INTENSIDADE DE UM FEIXE DE RAIOS X . . . . .	8
2.6	ATENUAÇÃO . . . . .	8
2.7	RADIOGRAFIA INDUSTRIAL . . . . .	9
2.7.1	Princípio de Inspeção por Meio da Radiografia . . . . .	10
2.7.2	Parâmetros Para Obtenção de Radiografias . . . . .	11
2.7.3	Dispositivos de Carga Acoplada . . . . .	13
<b>3</b>	<b>PROCESSAMENTO DIGITAL DE IMAGENS RADIOGRÁFICAS</b>	<b>14</b>
3.1	PRÉ-PROCESSAMENTO . . . . .	14
3.2	SEGMENTAÇÃO . . . . .	15
3.2.1	Detecção do Objeto de Interesse . . . . .	15
3.2.2	Segmentação de Bordas . . . . .	16
3.3	EXTRAÇÃO DE CARACTERÍSTICAS . . . . .	16
3.3.1	Características Geométricas . . . . .	16
3.3.2	Características Topológicas . . . . .	17
3.4	GRADIENTE DE UMA IMAGEM . . . . .	18
3.5	MORFOLOGIA MATEMÁTICA . . . . .	19
3.5.1	Operadores Morfológicos em Imagens Binárias . . . . .	20
3.5.2	Operadores Morfológicos em Níveis de Cinza . . . . .	22
<b>4</b>	<b>RECONHECIMENTO DE PADRÕES UTILIZANDO REDES NEURAI</b>	<b>24</b>
4.1	PADRÕES E CLASSES . . . . .	24
4.2	REDES NEURAI ARTIFICIAIS . . . . .	25

4.2.1	Modelo de Um Neurônio . . . . .	25
4.2.2	Perceptrons de Uma Camada . . . . .	27
4.2.3	Perceptrons de Múltiplas Camadas . . . . .	27
4.3	COMPONENTES PRINCIPAIS DE DISCRIMINAÇÃO . . . . .	30
<b>5</b>	<b>MATERIAIS E EQUIPAMENTOS</b>	<b>31</b>
5.1	AMOSTRAS DE ISOLADORES DE POLIMÉRICOS . . . . .	31
5.2	SISTEMA CT2000 . . . . .	32
5.3	SISTEMA RDP . . . . .	33
5.4	INSTRUMENTAÇÃO PARA COMPOSIÇÃO DO SISTEMA RDP . . . . .	35
5.4.1	Controle e Alimentação do Gerador Portátil de Raios X . . . . .	36
5.4.2	Alimentação do Módulo de Imagem . . . . .	37
5.4.3	Controle do <i>Trigger</i> . . . . .	38
5.5	CONFIGURAÇÃO DO SISTEMA COMPUTACIONAL . . . . .	39
<b>6</b>	<b>METODOLOGIA EXPERIMENTAL</b>	<b>43</b>
6.1	AQUISIÇÃO DAS RADIOGRAFIAS . . . . .	44
6.2	PRÉ-PROCESSAMENTO . . . . .	45
6.3	SEGMENTAÇÃO . . . . .	45
6.3.1	Extração da Região de Interesse - ROI . . . . .	45
6.3.2	Segmentação dos Defeitos Reais e Hipotéticos . . . . .	47
6.4	EXTRAÇÃO DAS CARACTERÍSTICAS . . . . .	48
6.5	CLASSIFICAÇÃO . . . . .	49
<b>7</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>51</b>
7.1	DETERMINAÇÃO DO COEFICIENTE DE ATENUAÇÃO LINEAR DO POLIETILENO DE ALTA DENSIDADE . . . . .	51
7.2	LIMITE DE DETECÇÃO DOS SISTEMAS CT2000 E RDP . . . . .	53
7.3	SEGMENTAÇÃO DAS IMAGENS . . . . .	55
7.4	LEVANTAMENTO DAS CARACTERÍSTICAS . . . . .	56
7.5	CLASSIFICAÇÃO . . . . .	56
<b>8</b>	<b>CONCLUSÕES</b>	<b>64</b>
8.1	SUGESTÕES PARA TRABALHOS FUTUROS . . . . .	65
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>66</b>

# Lista de Figuras

2.1	Efeito fotoelétrico. Com o eletrodo 1 iluminado com luz monocromática de intensidade constante, uma corrente $I$ é medida como uma função da diferença de potencial $V_{21}$ [6]. . . . .	5
2.2	Gráfico da corrente $i$ em função da voltagem $V$ para o efeito fotoelétrico [5]. . . . .	5
2.3	Tubo de raios X. Ao se aquecer o filamento do cátodo, pela passagem de uma corrente, elétrons são emitidos e acelerados em direção ao ânodo (alvo) pela diferença de potencial $V$ . Raios X são emitidos do alvo quando os elétrons são desacelerados ao atingi-lo. . . . .	6
2.4	Características dos raios X:(a) Espectro contínuo [9]. (b) Intensidade de raios X produzidos quando elétrons de 30 keV incidem em um alvo de Mo em função do comprimento de onda [10]. . . . .	7
2.5	O processo de <i>bremsstrahlung</i> responsável pela produção do espectro contínuo de raios X. . . . .	8
2.6	Feixe de raios X com seção transversal $A$ atingindo um material de espessura $x$ [7]. . . . .	9
2.7	Coefficiente de atenuação de massa, $\mu/\rho$ , e o coeficiente de absorção de massa-energia, $\mu_{en}/\rho$ em função da energia do fóton para o ar e para o polietileno puro [12]. . . . .	10
2.8	Representação de um ensaio para radiografia com filme. . . . .	11
2.9	Indicador de Qualidade de Imagens (IQI) [17]. . . . .	12
2.10	Representação do efeito penumbra na radiografia. . . . .	13
3.1	Máscara típica para implementar o filtro gaussiano. . . . .	15
3.2	Centróide (ponto vermelho) e caixa (em verde) que envolve a região. . . . .	16
3.3	Defeito (esquerda) e gráfico ilustrando a variação da coordenada X do centro de massa do defeito em relação ao eixo Y (direita). . . . .	18
3.4	Exemplos de interação do elemento estruturante numa imagem binária. . . . .	19
3.5	Exemplo de dilatação numa imagem binária. . . . .	20
3.6	Exemplo de erosão numa imagem binária. . . . .	21
3.7	Exemplo de abertura numa imagem binária. . . . .	21
3.8	Exemplo de fechamento numa imagem binária. . . . .	21
3.9	Operação <i>top-hat</i> em nível de cinza. Preserva os picos melhorando o contraste da imagem . . . .	23
3.10	Operação <i>bottom-hat</i> em nível de cinza. Preserva os vales melhorando o contraste da imagem. . .	23
4.1	Modelo de um neurônio artificial [2]. . . . .	26

4.2	Ilustração do hiperplano (aqui, uma reta) como fronteira de decisão para um problema de classificação linear de padrões bidimensional de duas classes [2]. . . . .	28
4.3	Arquitetura de uma rede múltipla camada com uma camada intermediária e uma camada de saída [2]. . . . .	29
5.1	Isolador polimérico classe 15 kV na linha de distribuição. . . . .	31
5.2	Amostras de isoladores poliméricos classe 15 kV utilizadas. . . . .	32
5.3	SISTEMA CT2000 (figura fora de escala). . . . .	32
5.4	Radiografia isolador polimérico (fabricante E, 70 kV e 3 mA). . . . .	33
5.5	SISTEMA RDP (figura fora de escala). . . . .	34
5.6	Fonte de raios X microfoco portátil do SISTEMA RDP. . . . .	35
5.7	Radiografia do isolador polimérico obtida com o SISTEMA RDP (70 kV, 100 $\mu$ A, 3 s de integração). . . . .	35
5.8	Vista frontal, computador e controle do tubo de raios X do SISTEMA RDP. . . . .	36
5.9	Esquema para controle do tubo de raios X do Sistema RDP. . . . .	37
5.10	Rack portátil com o controle da fonte de raios X do Sistema RDP e o computador do sistema. . . . .	37
5.11	Diagrama ilustrando o circuito utilizado para a montagem do carregador de baterias. . . . .	38
5.12	(a) Fontes montadas para alimentação do módulo de imagens. (b) Conector serial RS 232C, tipo DB9. . . . .	39
5.13	Diagrama fontes de alimentação do <i>Flat Panel</i> : (a) Fonte 5 V e (b) $\pm 7.5$ V. . . . .	40
5.14	Modo de integração (Trigger): (a) Circuito utilizado para o <i>Trigger</i> . O sinal é enviado pelo computador através do pino 3 e 5 da RS232C. (b) Pulsos do sinal de entrada e saída do <i>Trigger</i> no circuito da figura 5.14a. . . . .	41
5.15	GUIs ( <i>Guide User Interfaces</i> ) utilizada para a interface com o usuário desenvolvida em MATLAB: (a) Protótipo XDetector (b) Programa para treinamento da rede neural (COPPE/UFRJ). . . . .	42
6.1	Fluxograma mostrando as etapas de PDIR realizadas neste trabalho. . . . .	43
6.2	Aquisição das Radiografias com o SISTEMA CT2000 (70 kV, 3 mA, fabricante E). . . . .	44
6.3	Sub-imagens obtidas a partir das radiografias originais na figura 6.2. Utilizou-se um filtro gaussiano nestas imagens. . . . .	45
6.4	Histograma dos valores resultantes do passo 3 no método de detecção da ROI. . . . .	46
6.5	(a) Imagem filtrada extraída a partir de coordenadas pré-definidas. (b) Inverso da imagem obtida pela limiarização a partir de <i>pixels</i> de alto gradiente. (c) ROI = (a)x(b). . . . .	46
6.6	Identificação da ROI. . . . .	47
6.7	Resultados do algoritmo de segmentação de defeitos reais e hipotéticos. . . . .	49
6.8	Defeitos reais e hipotéticos segmentados. . . . .	49
7.1	Modelo utilizado para a determinação do coeficiente de absorção linear do HDPE. . . . .	51

7.2	Radiografia digital da amostra de HDPE em forma de escada. As setas indicam o caminho para o perfil obtido: (a) SISTEMA CT2000 (110 kV, 5 mA, fator de zoom 4) e em (b) SISTEMA RDP (70 kV, 100 $\mu$ A, fator de integração 5 s). . . . .	52
7.3	Perfil de nível de cinza obtido através das imagens da figura 7.2: (a) SISTEMA CT2000 e do (b) SISTEMA RDP. . . . .	53
7.4	Gráficos utilizados para a determinação do coeficiente de absorção linear médio através do (a) SISTEMA CT2000 e do (b) SISTEMA RDP. . . . .	54
7.5	Representação dos feixes de raios X atravessando a amostra para a simulação do limite de detecção dos SISTEMAS CT2000 e RDP. . . . .	54
7.6	Simulação da sensibilidade do nível de cinza em função do tamanho do defeito:(a) SISTEMA CT2000 (256 níveis) (b) SISTEMA RDP (4096 níveis). . . . .	55
7.7	(a) Simulação realizada para o contraste da imagem em função do tamanho do defeito. (b) Intensidade <i>versus</i> espessura para os dados simulados, a partir do sistema RDP e CT2000. . . . .	55
7.8	Imagem utilizada para estudo do valor de H. . . . .	56
7.9	Comparação para valores de H na operação de limiarização para a imagem da figura 7.8. . . . .	56
7.10	Resultado da segmentação dos defeitos hipotéticos. . . . .	57
7.11	Ilustração do grupo de dados obtidos após o cálculo das características das regiões segmentadas. . . . .	58
7.12	(a) Característica 11 <i>versus</i> característica 4 (b) característica 5 <i>versus</i> característica 4. Os dados foram normalizados para que ficassem entre 1 e -1. . . . .	59
7.13	Componentes principais de discriminação linear (CPDL). . . . .	61
7.14	(a) Curvas de erro de treinamento e validação do conjunto 7 da tabela 7.3. (b) Curva ROC que permite o cálculo da confiabilidade de detecção de defeitos. . . . .	62



# Lista de Tabelas

5.1	COMPARAÇÕES ENTRE O SISTEMA CT2000 E SISTEMA RDP. . . . .	36
5.2	TAXA DE CORRENTE MÁXIMA NAS FONTES DO MÓDULO DE IMAGEM. . . . .	38
6.1	CARACTERÍSTICAS GEOMÉTRICAS CALCULADAS PARA A IMAGEM SEGMENTADA DA FIGURA 6.8 EM $0^0$ . . . . .	50
6.2	CARACTERÍSTICAS TOPOLÓGICAS CALCULADAS PARA A IMAGEM SEGMENTADA DA FIGURA 6.8 EM $0^0$ . . . . .	50
7.1	MATRIZ COM COEFICIENTES DE CORRELAÇÃO LINEAR. . . . .	60
7.2	OTIMIZAÇÃO DO NÚMERO DE NEURÔNIOS NA CAMADA INTERMEDIÁRIA DO CLAS- SIFICADOR NÃO-LINEAR. . . . .	60
7.3	CÁLCULO DA ACURÁCIA DE CLASSIFICAÇÃO COM O CLASSIFICADOR NÃO-LINEAR. O ASTERISCO INDICA O CONJUNTO UTILIZADO PARA PLOTAR O GRÁFICO DA FI- GURA 7.14a. . . . .	61
7.4	CÁLCULO DOS VALORES DE FP E VP PARA OS 10 CONJUNTOS DE TESTES SORTEADOS.	63

# Lista de Siglas

AGERGS-RS - Agência Estadual de Regulação dos Serviços Públicos Delegados do Rio Grande do Sul

ASCII - *American Standard Code for Information Interchange*

CCD - *Charge-Coupled Device*

CMOS - *Complementary Metal Oxide Semiconductor*

CNEN - Comissão Nacional de Energia Nuclear

CPDL – Componente Principal de Discriminação Linear

CTS - *Clear To Send*

DEC - Duração Equivalente de Interrupção por Consumidor

END - Ensaios Não-Destrutivos

FEC - Frequência Equivalente de Interrupção por Consumidor

FP - Falso Positivo

HDPE - *High Densit Polyethylene*

PDIR - Processamento Digital de Imagens Radiográficas

RAD - *Radiation Absorbed Dose*

ROC - *Receiver Operating Characteristic*

ROI - *Region Of Interest*

URL - *Uniform Resource Locator*

VP - Verdadeiro Positivo

## RESUMO

Este trabalho apresenta os resultados obtidos na detecção de defeitos em isoladores poliméricos utilizados em linhas de distribuição de energia elétrica (classe 15 kV) por radiografia digital, utilizando as técnicas de processamento digital de imagens e reconhecimento de padrões e ainda a montagem de um sistema de radiografia digital portátil (denominado SISTEMA RDP). Foram utilizados 52 amostras de isoladores de 5 fabricantes diferentes. De cada amostra, 4 radiografias foram obtidas com um sistema de tomografia industrial (denominado SISTEMA CT2000) em 4 diferentes ângulos obtendo-se 208 imagens para aplicação das técnicas de processamento digital de imagens (PDI) e reconhecimento de padrões (RP). Os métodos de segmentação apresentaram ótimos resultados. Para a segmentação da ROI (*Region of Interest*) utilizaram-se *pixels* com alto gradiente. Para a segmentação dos defeitos hipotéticos utilizou-se as operações morfológicas (*tophat* e *bottomhat*). O número de regiões segmentadas correspondeu a 714. Um banco de dados com 13 características das 714 regiões segmentadas foi utilizado para o treinamento da rede neural. Após inspeção visual humana, a partir das radiografias obtidas, verificou-se que dessas regiões, 60 eram defeitos reais (D) e 654 estruturas regulares (ER). Os algoritmos utilizados para o RP mostraram resultados satisfatórios para a detecção dos defeitos nas radiografias dos componentes ensaiados. Os resultados desta dissertação são motivadores para a implementação de um sistema de inspeção automático tanto em linhas de produção dos isoladores poliméricos quanto nas redes de distribuição.

**Palavras-chaves:** Isoladores, radiografia digital, processamento de imagens, reconhecimento de padrões.

## ABSTRACT

This work introduces the results obtained in the detection of defects in polymeric insulators used in electric power distribution lines (15 kV class) by digital radiography, in which digital image processing, pattern recognition and the assembling of a portable digital radiography system (here named RDP SYSTEM) were used. 52 insulator samples from 5 different manufacturers were used. From each sample 4 radiographies were obtained by using an industrial tomography system (here named CT2000 SYSTEM) in 4 different angles, which yield 208 images for the application of digital image processing (DIP) and pattern recognition (PR) techniques. The segmenting methods generated great results. For ROI (Region of Interest) segmentation high gradient pixels were used. For the segmentation of hypothetical defects, morphological operations (tophat and bottomhat) were used. The number of segmented regions corresponded to 714. A database with 13 features of the 714 segmented regions was built up for the training of the neural net. After human visual inspection for the obtained x-rays, it was verified that of those regions, 60 were real defects (D) and 654 were regular structures (RS). The algorithms used for the PR showed satisfactory results for the detection of the defects in the x-ray of the assayed components. The results of this work are satisfactory for the implementation of an automatic inspecting system in either the polymeric-insulator production lines or electric power distribution lines.

**Keywords:** Insulators, digital radiography, digital image processing, pattern recognition.

# Capítulo 1

## INTRODUÇÃO

Os Ensaios Não-Destrutivos (END) alcançaram importante relevância na avaliação da qualidade dos materiais e equipamentos, seja no processo de fabricação ou durante o período de funcionamento dos mesmos, pois as indústrias estão voltadas para a melhoria da qualidade de seus produtos; requisito básico para manter-se competitivo nos mercados nacionais e internacionais [1].

Dentre os ensaios não-destrutivos, a radiografia é um dos métodos mais antigos. Entre as vantagens fornecidas por ela está o fato de a imagem obtida representar uma fotografia interna da peça, assim pode-se avaliar a amostra em todo o seu volume.

Porém, o método convencional de inspeção radiográfica exige que a qualidade da imagem seja a melhor possível. Além disso, sabe-se que, a inspeção visual humana da radiografia é conduzida de forma que, em certos casos, deixa margem à interpretação subjetiva, necessitando-se que o inspetor possua extrema experiência, acuidade visual e conhecimento da técnica empregada.

A medida a ser tomada com respeito a aprovação ou não da peça, após a inspeção radiográfica, dependerá da localização, do tamanho e do tipo de defeito encontrado. Neste caso, é de suma importância a precisão da análise das imagens obtidas.

Nas radiografias de isoladores poliméricos, o contraste entre um defeito (bolha ou trinca) e a área livre de defeito nem sempre é perceptível visualmente, o que reforça a necessidade da utilização de técnicas de processamento de imagens e reconhecimento de padrões com algoritmos de inteligência artificial<sup>1</sup> implementados para a análise desses componentes.

Os avanços na tecnologia de detectores (como o de silício amorfo) e fontes de raios X (como a fonte microfoco), permitem visualizar defeitos em peças da ordem de 0.5 mm em baixo contraste (como por exemplo, ar e polímero). Isto, aliado aos progressos no campo da informática e das ciências ligadas aos processos baseados em reconhecimentos de padrões, permitem o surgimento de várias pesquisas voltadas para se estudar e avaliar metodologias que possam ser usadas para desenvolver um sistema automático, ou semi-automático, de análise de radiografias industriais com grande precisão.

---

<sup>1</sup>Existem várias definições para o que seja Inteligência Artificial. Aqui considera-se como sendo um processo implementado em *hardware* ou *software* visando realizar tarefas usualmente feitas por seres humanos [2].

## OBJETIVOS

O objetivo do trabalho centrou-se na montagem de um sistema de radiografia digital portátil, que será denominado SISTEMA RDP, o qual implicou no desenvolvimento da instrumentação eletrônica (equipamentos) e dos algoritmos (programas), para a detecção (semi ou automática) de defeitos em isoladores poliméricos da classe 15 kV utilizados em linhas de distribuição de energia elétrica, com a possibilidade de aplicação deste sistema tanto no campo de trabalho do isolador (análise no poste) quanto na linha de produção do mesmo.

As etapas de desenvolvimento do trabalho podem ser divididas na (i) configuração do SISTEMA RDP, tais como as pesquisas de mercado e de compatibilidade entre os componentes, (ii) montagem do sistema, ocorrido após o recebimento dos equipamentos que vieram do exterior (detector e tubo de raios X), os quais exigiram uma instrumentação dedicada para controlar o equipamento e os programas, (iii) testes de funcionamento do sistema RDP (iv) desenvolvimento dos algoritmos de processamento de imagens para segmentação dos defeitos hipotéticos e levantamento das características (geométricas e topológicas) das regiões segmentadas, o que foi realizado com radiografias obtidas com o SISTEMA CT2000 para futuramente serem aplicados no sistema portátil, (v) o levantamento da acurácia do treinamento da rede neural no processo de reconhecimento de padrões utilizados e (vi) a automatização do processo de detecção de defeitos reais através da implementação de uma rede neural com técnicas de reconhecimento de padrões desenvolvidas.

## JUSTIFICATIVAS

Isoladores poliméricos estão tornando-se cada vez mais utilizados e ganhando uma grande fatia do mercado de componentes elétricos devido as suas vantagens em relação aos isoladores tradicionais de vidro ou cerâmicas, como por exemplo: baixo peso, alta resistência mecânica, melhor resistência ao vandalismo, melhor resistência às condições de poluição em ambientes úmidos e melhor performance elétrica [3].

A motivação para esta dissertação de mestrado está numa das principais causas de falha dos isoladores utilizados em redes de distribuição de energia elétrica: a existência de vazios na estrutura dos materiais utilizados na fabricação.

Estes vazios podem ser originados pela formação de bolhas de ar durante o processo de injeção do polímero no processo de fabricação ou por trincas ocasionadas pela fadiga devida aos estresses mecânicos e térmicos sofridos durante a operação ou, ainda, pela má colocação de massa de fixação no isolador.

A ação do campo elétrico aplicado e a existência de condições adequadas, como a pressão do gás no interior do vazio, permitem a ocorrência de descargas parciais. A constante ocorrência destas no interior desses defeitos formam caminhos condutores no polímero conhecidos como arborescência elétrica, no sentido do campo elétrico aplicado, os quais levarão o material à ruptura dielétrica. O isolador danificado causa o desligamento da linha, gerando custos de manutenção com a reposição desses componentes e o aumento do tempo de interrupção do fornecimento de energia elétrica aos consumidores, piorando os índices de Duração Equivalente de Interrupção por Consumidor (DEC) e de Frequência Equivalente de Interrupção por Consumidor (FEC) da concessionária<sup>2</sup>.

---

<sup>2</sup>Para saber como se calcula os índices DEC e FEC ver URL da AGERGS-RS [4].

## **ORGANIZAÇÃO DA DISSERTAÇÃO**

Esta dissertação está organizada conforme segue. Os capítulos 2 a 4 trazem a revisão bibliográfica dos assuntos abordados no trabalho. O capítulo 2 refere-se aos princípios de radiografia, com ênfase em radiografia industrial. No capítulo 3 as principais ferramentas utilizadas em processamento digital de imagens radiográficas são apresentadas. No capítulo 4 os principais conceitos da aplicação de redes neurais em reconhecimento de padrões são abordados. Após estes capítulos de revisão, seguem os materiais e as metodologias utilizadas no trabalho. No capítulo 5 os materiais e equipamentos são descritos, com toda a instrumentação para a composição SISTEMA RDP sendo mostrada. No capítulo 6 apresentam-se as metodologias experimentais utilizadas. O capítulo 7 apresenta e discute os resultados deste trabalho. Finalmente, o capítulo 8 traz as conclusões com uma seção para trabalhos futuros.

## Capítulo 2

# PRINCÍPIOS DE RADIOGRAFIA

Este capítulo aborda os principais conceitos referentes à interação dos fótons com a matéria e os princípios da radiografia. Mesmo sendo matéria bastante explorada em livros e artigos, optou-se por escrever sobre esses conceitos fundamentais à produção de raios X com o intuito de introduzir o leitor não especialista ao assunto. As referências para este capítulo são os livros de Eisberg e Resnick [5], Johns e Cunningham [6], Shung *et al* [7] e Halliday *et al* [8].

## 2.1 O FÓTON

Em 1905, Albert Einstein (1879 - 1955) propôs que a radiação eletromagnética seria quantizada; a quantidade elementar de radiação é hoje chamada de fóton. Segundo Einstein, um quantum de luz de frequência  $f$  tem uma energia dada por

$$E = hf \quad (2.1.1)$$

onde  $h$  é a chamada constante de Planck, que tem o valor igual a  $6,63 \times 10^{-34} \text{ J.s} = 4,14 \times 10^{-15} \text{ eV.s}$ .

A menor energia que uma onda luminosa de frequência  $f$  pode possuir é  $hf$ . Se a onda possui energia maior, esta deve ser um múltiplo inteiro de  $hf$ .

Einstein propôs ainda que sempre que a radiação é absorvida ou emitida por um corpo, esta absorção ou emissão ocorre nos átomos do corpo. Quando um fóton de frequência  $f$  é absorvido por um átomo, a energia  $hf$  do fóton é transferida da luz para o átomo. Este evento implica a aniquilação de um fóton. Quando um fóton de frequência  $f$  é emitido por um átomo, uma energia  $hf$  é transferida do átomo para a radiação. Este evento implica a criação de um fóton.

## 2.2 O EFEITO FOTOELÉTRICO

Em 1886 e 1887, Heinrich Hertz realizou as experiências que, pela primeira vez, confirmaram a existência de ondas eletromagnéticas e a teoria de Maxwell sobre a propagação da luz. Hertz descobriu que uma descarga



elétrica entre dois eletrodos ocorre mais facilmente quando se faz incidir sobre um deles luz ultravioleta. A emissão de elétrons de uma superfície, devido à incidência de luz sobre essa superfície, é chamada **efeito fotoelétrico**.

A figura 2.1 pode ser utilizada para ilustrar este efeito experimentalmente. Luz incidente monocromática entra num tubo de vidro, que está em vácuo, através de uma janela de quartzo (que permite passar apenas luz ultravioleta) e colide com o eletrodo metálico 1 fornecendo energia para que os fotoelétrons sejam ejetados. A corrente  $I$  que flui durante a incidência da luz pode ser medida como uma função da variável diferença de potencial  $V_{21}$  aplicada entre os eletrodos 1 e 2.




Figura 2.1: Efeito fotoelétrico. Com o eletrodo 1 iluminado com luz monocromática de intensidade constante, uma corrente  $I$  é medida como uma função da diferença de potencial  $V_{21}$  [6].

As curvas  $a$  e  $b$  na figura 2.2 são gráficos da corrente fotoelétrica, em um aparelho como o mostrado na figura 2.1, em função da diferença de potencial  $V$ . Se  $V$  é muito grande, a corrente atinge um certo valor limite (ou de saturação) no qual todos os fotoelétrons emitidos por 1 são coletados por 2.




Figura 2.2: Gráfico da corrente  $i$  em função da tensão  $V$  para o efeito fotoelétrico [5].

Se o sinal de  $V$  é invertido, a corrente fotoelétrica não cai imediatamente a zero, o que sugere que os elétrons são emitidos com alguma energia cinética. O valor  $V_0$  é chamado potencial limite ou de corte.

## 2.3 O EFEITO COMPTON

Compton pode confirmar em 1923 a natureza corpuscular da radiação. Ele fez com que um feixe de raios X incidisse sobre um alvo de grafite. Mediu-se então a intensidade dos raios X espalhados como função de seu comprimento de onda, para vários ângulos de espalhamento.

## 2.4 PRODUÇÃO DE RAIOS X

Os raios X, denominados assim por sua natureza então desconhecida quando o físico alemão Wilhelm Conrad Röntgen no dia 8 de novembro de 1895 fez suas primeiras observações, são produzidos no alvo de um tubo como o ilustrado na figura 2.3. Quando um feixe de elétrons de alta energia, acelerados por uma diferença de potencial de alguns milhares de volts, é freado ao atingir um alvo metálico, causa a emissão de um espectro contínuo de radiação eletromagnética.




Figura 2.3: Tubo de raios X. Ao se aquecer o filamento do cátodo, pela passagem de uma corrente, elétrons são emitidos e acelerados em direção ao ânodo (alvo) pela diferença de potencial  $V$ . Raios X são emitidos do alvo quando os elétrons são desacelerados ao atingi-lo.

O choque do feixe elétrons, que saem do cátodo com energia da ordem de 30 keV, com o ânodo (alvo), produz um espectro contínuo, que resulta da desaceleração do elétron durante a penetração no ânodo. Pode-se falar em raios X característico do material do ânodo também. Assim, cada espectro de raios X é a superposição de um espectro contínuo e de uma série de linhas espectrais características do ânodo.

O espectro contínuo é uma curva de contagens por segundo versus comprimento de onda do raio X. Como se viu na seção 2.1 um fóton de radiação, com frequência  $f$ , transporta uma energia  $hf = hc/\lambda$ , onde  $\lambda$  é o comprimento de onda da radiação. Portanto, o raio X emitido deverá ter energia máxima igual à energia do elétron incidente. Assim, o espectro contínuo é limitado por este valor. Na figura 2.4a, têm-se vários espectros contínuos em função do potencial acelerador. Essas curvas foram obtidas com um alvo de tungstênio. É fácil compreender, a

partir das relações

$$E = hf = hc/\lambda \quad (2.4.1)$$

que o comprimento de onda (ou a frequência) inferior (ou superior) deve diminuir (ou aumentar) com o potencial acelerador. O comprimento de onda mínimo é  $\lambda_{min} = 1,24 \times 10^4 \text{ \AA}$ .

Substituindo-se o alvo de tungstênio ( $Z=74$ ) por um de molibdênio ( $Z=42$ ), e mantendo-se as outras condições experimentais constantes, obtém-se o resultado ilustrado na figura 2.4b.




Figura 2.4: Características dos raios X: (a) Espectro contínuo [9]. (b) Intensidade de raios X produzidos quando elétrons de 30 keV incidem em um alvo de Mo em função do comprimento de onda [10].

Observa-se que as principais diferenças entre as figuras 2.4a e 2.4b são os picos existentes na 2.4b, em torno de 0.6  $\text{\AA}$  e 0.7  $\text{\AA}$ . Levando-se em conta que a única diferença entre uma medida e outra foi a substituição do alvo, é razoável admitir que os picos são devidos ao ânodo de molibdênio. Estes picos constituem o espectro de raios X característico do molibdênio.

A figura 2.5 ilustra o processo elementar de produção de raios X. Um elétron de energia cinética inicial  $K_1$  é desacelerado pela interação com um núcleo pesado do alvo. A energia que este elétron perde aparece na forma de radiação como um fóton de raios X. A massa do núcleo em relação ao elétron é tão grande que a energia que ele adquire durante a colisão pode ser completamente desprezada. A energia do fóton pode ser dada por,

$$E = h\nu = K_1 - K_2 \quad (2.4.2)$$

onde  $K_2$  é a energia cinética do elétron após a colisão. O comprimento de onda do fóton de raios X é dado por,

$$\frac{hc}{\lambda} = K_1 - K_2 \quad (2.4.3)$$




Figura 2.5: O processo de *bremsstrahlung* responsável pela produção do espectro contínuo de raios X.

## 2.5 INTENSIDADE DE UM FEIXE DE RAIOS X

A intensidade de um feixe de raios X é uma função do número de fótons. Três unidades são frequentemente utilizadas para indicar a dose absorvida de raios X: o **R** (röntgen), o **rad** (*radiation absorbed dose*) e o **Gy** (gray) [7].

A razão pelo qual o raio X é denominado de radiação ionizante tem como princípio que ele possui energia suficiente para causar a ionização dos átomos. A grandeza exposição foi a primeira grandeza definida para fins de radioproteção. Esta grandeza é uma medida da habilidade ou capacidade dos raios X e  $\gamma$  em produzir ionizações no ar. Ela mede a carga elétrica total produzida por raios X e  $\gamma$  em um quilograma de ar. A unidade atual da grandeza exposição é o coulomb por quilograma (C/kg) em condições normais de temperatura e pressão. A unidade antiga é o roentgen (R) que equivale a  $2,58 \times 10^{-4}$  C/kg (1 atm, 25°C) [11].

A unidade rad define a quantidade de radiação absorvida. Um rad significa que 0,01 J de energia é absorvida por 1 kg de material (1 Gy = 100 rad). Diferentes materiais têm diferentes características de absorção de raios X.

## 2.6 ATENUAÇÃO

Quando o feixe de raios X atinge um material, sua energia diminui devido à interação dos fótons com o matéria como visto anteriormente. Assuma que o feixe de raios X tem uma intensidade  $I$  e uma seção transversal de área  $A$  conforme mostra a figura 2.6. Assuma também que os átomos no material são idênticos e todos possuem seção transversal  $\sigma$  com uma densidade de  $n$  átomos por unidade de volume. Então, o número total de átomos encontrado pelo feixe de raios X é dado por  $An$  e a área ocupada pelos átomos no feixe incidente é  $An\sigma$ . Assim a probabilidade para que um fóton interaja com um átomo é  $An\sigma/A = n\sigma$ . A energia dos raios X removida numa espessura  $dx$  do material é

$$dI = -n\sigma I dx \quad (2.6.1)$$

Rearranjando a equação 2.6.1, fazendo  $\mu = n\sigma$  que é a fração de energia removida por unidade de

espessura por unidade de intensidade e integrando obtém-se

$$I = I_0 e^{-\mu x} \quad (2.6.2)$$

onde  $I$  é a intensidade de raios X em  $x$ ,  $I_0$  é a intensidade incidente no material,  $\mu$  é definido como o coeficiente de atenuação linear em  $\text{cm}^{-1}$ , e  $x$  é o comprimento de propagação do feixe no material. A equação 2.6.2 é conhecida como a lei de Beer-Bauguer e é válida somente para um feixe monoenergético.




Figura 2.6: Feixe de raios X com seção transversal  $A$  atingindo um material de espessura  $x$  [7].

O coeficiente de atenuação de massa é definido como a razão do coeficiente linear de atenuação ( $\mu$ ) pela densidade do material ( $\rho$ ). A unidade do coeficiente de atenuação de massa é  $\text{cm}^2/\text{g}$ . Este é muito útil porque indica a propriedade de atenuação da matéria independente do seu estado físico. Por exemplo, o coeficiente de atenuação linear da água líquida, do gelo e do vapor de água é  $0,214 \text{ cm}^{-1}$ ,  $0,196 \text{ cm}^{-1}$  e  $0,00013 \text{ cm}^{-1}$ , respectivamente, a 50 keV. Entretanto o coeficiente de atenuação de massa é o mesmo para os três estados da água ( $0,214 \text{ cm}^2/\text{g}$ ).

A figura 2.7 mostra a curva do coeficiente de atenuação de massa,  $\mu/\rho$ , e o coeficiente de massa de absorção de energia,  $\mu_{en}/\rho$  como função da energia do fóton para dois materiais (ar e polietileno puro) [12]. A razão para se mostrar estes dados aqui está intimamente relacionada com o objeto de estudo deste trabalho: a composição do material de que é feito o isolador polimérico (polietileno) e do material existente dentro dos defeitos (ar).

## 2.7 RADIOGRAFIA INDUSTRIAL

Segundo a Comissão Nacional de Energia Nuclear (CNEN), no Brasil, as aplicações industriais de radiações ionizantes são realizadas em cerca de 900 indústrias, nas quais são manuseadas em torno de 3.000 fontes radioativas. A radiografia industrial representa 14% desse total, com 217 equipamentos de raios X cadastrados e 287 irradiadores para gamagrafia industrial, que é uma técnica similar à radiografia e visa ao controle de qualidade de peças metálicas ou de estruturas de concreto [13].




Figura 2.7: Coeficiente de atenuação de massa,  $\mu/\rho$ , e o coeficiente de absorção de massa-energia,  $\mu_{en}/\rho$  em função da energia do fóton para o ar e para o polietileno puro [12].

Apesar do número reduzido de indústrias brasileiras que fornecem serviços em radiografia, esta técnica vem crescendo neste setor dada as suas vantagens, como: controle de qualidade do produto, redução de riscos operacionais de equipamentos e componentes, desenvolvimento de sistemas de inspeção radiográfica mais baratos e de grande área de detecção [14], automatização do sistema de inspeção, etc.

Nesta seção, o estado da arte da radiografia industrial é apresentado.

### 2.7.1 Princípio de Inspeção por Meio da Radiografia

O princípio de inspeção radiográfica baseia-se no fato de que as radiações incidentes na peça ensaiada são modificadas pela passagem em discontinuidades ou defeitos que possam estar presentes, provocando alteração na intensidade da radiação emergente da peça ensaiada, aonde alterações de espessura e presença de discontinuidades são visualizadas por diferenças de contraste nas imagens obtidas [16]. A radiação que atravessa a peça é então detectada por um filme ou ainda por sistemas com intensificadores de imagens acoplados a sistemas CCDs.

Em radiografia industrial coloca-se a peça a ser ensaiada entre uma fonte emissora de radiação (raios X ou  $\gamma$ ) e um detector (filme ou cintilador). Imagens de raios X tradicionais são baseadas no contraste de absorção das partes de um objeto [15, 16]. Progressos no aumento da qualidade dos detectores têm sido feito, tais como, placas de imagens (*image plates*), módulos de imagens (*flat panels*) com detectores que possuem matriz CCDs a base de Si amorfo, câmeras CCDs, etc. Nas fontes também existem progressos, tais como a microfoco. A figura 2.8 mostra um arranjo para a realização de uma radiografia convencional. A intensidade do feixe de raios X que atinge o filme radiográfico ou sensor num determinado ponto depende da atenuação sofrida pelo feixe no caminho percorrido.




Figura 2.8: Representação de um ensaio para radiografia com filme.

## 2.7.2 Parâmetros Para Obtenção de Radiografias

### Energia do Feixe

O primeiro parâmetro a ser observado para a realização de uma radiografia é a energia do feixe de raios X ou  $\gamma$ . Conforme visto no capítulo anterior, o coeficiente de absorção de um material é dependente da energia e em geral decresce quando a energia aumenta.

Na radiografia industrial a energia escolhida deve ser suficiente para atravessar o objeto e emergir com uma intensidade suficiente para sensibilizar o detector e, também, gerar um contraste satisfatório para visualização do defeito.

### Contraste da Imagem

Tipicamente, os sensores são capazes de discretizar os valores de uma cena em um intervalo que vai de  $L_{min}$  a  $L_{max}$ . Contraste (ou modulação) depende da diferença de tom entre duas regiões vizinhas de uma imagem e é determinado pela expressão

$$C(\%) = \frac{L_2 - L_1}{L_{max} - L_{min}} 100\% \quad (2.7.1)$$

onde  $C$  é o contraste da imagem,  $L_1$  a intensidade da imagem na região 1,  $L_2$  a intensidade da imagem na região 2,  $L_{max}$  a intensidade máxima da imagem e  $L_{min}$  a intensidade mínima da imagem.

Em imagens digitais de 8 bits existem 256 tons de cinza, sendo que  $L_{min} = 0$  corresponde ao preto e  $L_{max} = 255$ , corresponde ao branco. Já em imagens de 12 bits, como as fornecidas pelo SISTEMA RDP mostrado no capítulo 7, têm-se 4096 níveis de cinza. Estes parâmetros estão relacionados à resolução em profundidade dos *pixels* e também pela saída digital do equipamento utilizado para adquirir as imagens.

Na figura 2.9 ilustra-se um exemplo de IQI (Indicador de Qualidade de Imagens). Estes são utilizados para se obter uma medida do contraste e da definição da imagem obtida [17].



Figura 2.9: Indicador de Qualidade de Imagens (IQI) [17].

### Resolução Espacial

A resolução de um dispositivo ou sistema representa sua capacidade de apresentar fielmente pequenos detalhes ou variações de uma imagem. A resolução pode ser expressa em diversas unidades: *pixels*/mm, *pixels*/polegada, pares de linha/mm, etc. Existem dois tipos de resolução: resolução de alto contraste e resolução de baixo contraste.

A resolução de alto contraste representa a capacidade de um sistema de representar fielmente imagens com grandes variações de intensidades. Um método comumente empregado para determinar a resolução de alto contraste de um dispositivo consiste em observar a imagem de uma sequência de linhas escuras e claras alternadas, de forma a produzir altos valores de contraste.

A resolução de baixo contraste representa a capacidade de um sistema de apresentar detalhes com pequenas variações de intensidades. Em radiografia e tomografia, este parâmetro é a capacidade de mostrar pequenas variações de coeficientes de atenuação. A resolução de baixo contraste deve ser expressa em termos do tamanho do menor detalhe e do contraste em relação ao meio (por exemplo, 1 mm a 1%).

Um método comum para determinar a resolução de baixo contraste de um sistema de radiografia é a utilização de um phantom com diversos furos de diferentes diâmetros.

### Dimensão do Foco da Fonte de Raios X

Outro parâmetro importante para obtenção de uma boa radiografia é a dimensão da fonte de radiação (*spot size*). O fato de que a fonte de raios X não é uma fonte pontual e apresenta uma dimensão  $f$ , faz com que vários raios passem pela borda do objeto formando o efeito penumbra com dimensão  $p$ . Na figura 2.10 é mostrada uma representação esquemática do efeito penumbra o qual gera uma baixa definição das bordas do objeto ou do defeito em análise.

Das relações geométricas pode-se determinar a dimensão da penumbra na imagem conforme,

$$p = f \left( \frac{D_{fd}}{D_{fo}} - 1 \right) \quad (2.7.2)$$

onde  $p$  é a dimensão linear da penumbra formada na imagem,  $f$  é a dimensão linear da fonte de raios X,  $D_{fd}$  é a distância da fonte ao detector e  $D_{fo}$  é a distância da fonte ao objeto.

Pela análise da equação 2.7.2, pode-se verificar que o principal fator para reduzir a penumbra formada na imagem é a dimensão da fonte  $f$ . Assim, é comum utilizar fontes de raios X com dimensões focais na ordem






Figura 2.10: Representação do efeito penumbra na radiografia.

de dezenas de micrometros (“microfoco”). Também, é possível otimizar os fatores geométricos do arranjo, como aumentar a distância da fonte ao detector e a distância da fonte ao objeto.

### 2.7.3 Dispositivos de Carga Acoplada

Os dispositivos de carga acoplada (CCDs) foram inventados em 1970 e atualmente são utilizadas em vários sistemas de visão de máquina. O coração das câmeras CCDs é a matriz de estado sólido. Ela converte a intensidade de luz em sinais de tensão. Apesar das câmeras serem popularmente chamadas de “Câmeras CCDs” elas podem conter ainda dispositivos de injeção de carga (CIDs) ou semicondutores metal-óxido (MOS) [18].

## Capítulo 3

# PROCESSAMENTO DIGITAL DE IMAGENS RADIOGRÁFICAS

O processamento digital de imagens radiográficas (PDIR) envolve normalmente as seguintes etapas listadas abaixo:

1. **Aquisição da imagem.** Nesta etapa as imagens são capturadas por dispositivos tais como câmeras CCDs, sensores planos, *imaging plates*, módulos de imagens. Essas imagens são convertidas em uma imagem digital (geralmente no padrão *bitmap*).
2. **Pré-processamento.** Realiza-se nesta etapa a restauração da imagem, corrigindo eventuais degradações ou imperfeições que ocorrem durante a aquisição da radiografia, que podem ser decorrentes do ruído presente no sistema [19].
3. **Segmentação.** Separação do objeto de interesse de outros objetos contendo informação irrelevante (*background*);
4. **Extração de características.** Obtenção de um conjunto de medidas ou valores que sejam similares para objetos pertencentes a mesma classe, e diferentes para objetos de classes distintas.
5. **Classificação.** Esta etapa tem como objetivo usar o vetor de entrada, obtido pelas características, para atribuir um objeto a uma classe.
6. **Decisão Final.** Pode existir em certos sistemas, como em linhas de produção. Envolve normalmente uma tomada de decisão a partir do resultado da classificação.

### 3.1 PRÉ-PROCESSAMENTO

A utilização de filtros passa-baixas é comumente utilizada na etapa de pré-processamento. Uma vez que as frequências altas que correspondem às transições abruptas (ruídos) são atenuadas. Desta forma, a suavização

tende também, pelas mesmas razões, a minimizar o efeito do ruído na imagem [20]. Um filtro passa-baixa muito utilizado para a suavização de ruídos é o filtro Gaussiano.

Nos filtros Gaussianos, os coeficientes da máscara usada são derivados de uma função Gaussiana bidimensional. A função Gaussiana bidimensional discreta com média nula é definida como

$$G(x, y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.1.1)$$

onde o parâmetro  $\sigma$  está relacionado com a largura do filtro Gaussiano. Quanto maior o valor de  $\sigma$ , maior a largura do filtro e maior o seu grau de suavização. A implementação deste filtro geralmente é realizada com a utilização de máscaras. A figura 3.1 ilustra uma máscara típica para implementar o filtro Gaussiano.

$$\begin{bmatrix} 1 & 1 & 2 & 2 & 2 & 1 & 1 \\ 1 & 2 & 2 & 4 & 2 & 2 & 1 \\ 2 & 2 & 4 & 8 & 4 & 2 & 2 \\ 2 & 4 & 8 & 16 & 8 & 4 & 2 \\ 2 & 2 & 4 & 8 & 4 & 2 & 2 \\ 1 & 2 & 2 & 4 & 2 & 2 & 1 \\ 1 & 1 & 2 & 2 & 2 & 1 & 1 \end{bmatrix}$$

Figura 3.1: Máscara típica para implementar o filtro gaussiano.

## 3.2 SEGMENTAÇÃO

A segmentação de imagens consiste na extração ou identificação de regiões de interesse contidos na imagem, onde a região é todo conteúdo semântico relevante para a aplicação desejada [20]. Em processamento de imagens radiográficas para detecção de falhas em isoladores, após as etapas de pré-processamento e segmentação, as regiões de interesse serão aquelas que contenham os defeitos reais (falhas realmente existentes) e os defeitos hipotéticos (estruturas regulares) [19, 21, 22, 23, 24]. O objetivo do sistema de inspeção radiográfica de isoladores é classificar corretamente estas duas classes de objetos existentes na imagem, o que torna possível uma decisão final sobre a aprovação ou reprovação da peça. Isto mostra o quanto é importante o resultado obtido com a segmentação.

### 3.2.1 Detecção do Objeto de Interesse

Realizada a etapa de pré - processamento da imagem torna-se importante que o algoritmo consiga diferenciar o que é isolador e o que não é, ou seja, podem-se retirar as regiões da imagem que não pertençam ao isolador para melhorar os resultados dos processos de análise seguintes, como custo computacional, por exemplo. O intuito é obter-se uma ROI (*Region of Interest*) para as etapas posteriores de processamento.

### 3.2.2 Segmentação de Bordas

As bordas correspondem a *pixels* da imagem os quais variam o valor do nível de cinza significativamente comparado aos seus vizinhos. Normalmente, as bordas são detectadas utilizando-se operadores de gradiente [19, 21, 22, 23, 25] . Um filtro *LoG* (lê-se Laplaciano do Gaussiano) e um algoritmo de zeros transversais (*zero crossing*) também pode ser utilizado para detectar bordas na imagem radiográfica [24]. Quoirin [26] recorreu a operadores morfológicos para segmentar os defeitos em imagens de tomografias de amostras de madeira .

## 3.3 EXTRAÇÃO DE CARACTERÍSTICAS

As regiões demarcadas pelas bordas, após a segmentação, são extraídas e cada uma delas pode ser descrita através de suas características geométricas e topológicas (ou de intensidade) regionais. Por exemplo, atributos geométricos como área, orientação, forma e topológicos como média do nível de cinza, textura, etc, podem ser obtidos das regiões e, posteriormente, utilizados no processo de classificação das regiões. Estes dados são importantes para o reconhecimento de padrões em imagens.

### 3.3.1 Características Geométricas

As características geométricas utilizadas neste trabalho são descritas a seguir:

**Área ( $C_1$ ):** Escalar. A área é definida como o número de *pixels* que pertencem à região. Neste trabalho, a área representa o número de *pixels* acesos (brancos) conectados com vizinhança de 8 *pixels* [16].

**Área preenchida ( $C_2$ ):** Escalar. O número de *pixels* na imagem binária de mesmo tamanho de uma caixa que cerca a região (figura 3.2). Os *pixels* acesos correspondem à região, com todos os buracos (*pixels* desligados - pretos) preenchidos.

**Centróide em x ( $C_3$ ):** Vetor. Coordenadas  $i$  do centro de massa da região.

**Centróide em y ( $C_4$ ):** Vetor. Coordenadas  $j$  do centro de massa da região.

A figura 3.2 ilustra o centróide (ponto vermelho) de uma imagem binária. A região em análise consiste de *pixels* acesos.




Figura 3.2: Centróide (ponto vermelho) e caixa (em verde) que envolve a região.

**Comprimento do maior eixo da região ( $C_5$ ):** Escalar. O comprimento (em *pixels*) do maior eixo de uma elipse que envolva a região.

**Comprimento do menor eixo** ( $C_6$ ): Escalar. O comprimento (em *pixels*) do menor eixo de uma elipse que envolva a região.

**Excentricidade** ( $C_7$ ): Escalar. A excentricidade de uma elipse que envolva a região. A excentricidade é a razão entre a distância entre os focos da elipse e seu eixo de maior comprimento. O valor está entre 0 and 1 (0 e 1 são casos especiais; uma elipse com excentricidade igual a 0 é um círculo, enquanto uma elipse cuja a excentricidade é 1 é um segmento de linha).

**Orientação** ( $C_8$ ): Escalar. O ângulo (em graus) entre o eixo-x e o maior eixo da elipse que envolve a região.

**Diâmetro equivalente** ( $C_9$ ): Escalar. O diâmetro de um círculo de mesma área da região, calculado conforme a equação,

$$C_9 = \sqrt{\frac{4A}{\pi}} = 2\sqrt{\frac{A}{\pi}} \quad (3.3.1)$$

onde  $A$  é a área da região e  $\pi$  uma constante.

### 3.3.2 Características Topológicas

Propriedades topológicas são úteis para descrições globais de regiões no plano da imagem. Topologia é o estudo das propriedades da figura que não são afetadas por qualquer tipo de deformação [25]. Com exceção do Número de Euler, estas características são calculadas utilizando-se os valores de cinza na imagem, onde  $f[i, j]$  denota o valor de cinza do pixel com coordenada  $(i, j)$ .

**Número de Euler** ( $C_{10}$ ): Escalar. Igual ao número de objetos na região menos o número de buracos naqueles objetos.

**Média dos Níveis de Cinza da Região** ( $C_{11}$ ): O valor médio do nível de cinza da região, calculado com a seguinte equação,

$$C_{11} = \frac{1}{A} \sum_{i,j \in \mathbb{R}} f[i, j] \quad (3.3.2)$$

onde  $\mathbb{R}$  é o grupo de *pixels* da região e  $A$  a área [21].

**Média da Segunda Derivada dos Níveis de Cinza da Região** ( $C_{12}$ ): Esta característica é calculada conforme a equação:

$$C_{12} = \frac{1}{A} \sum_{i,j \in \mathbb{R}} f''[i, j] \quad (3.3.3)$$

onde  $f''[i, j]$  é a segunda derivada no *pixel*  $(i, j)$  [21].


**Valor Máximo da Variação da Derivada da Posição do Centro de Massa da Região em Relação a Linha da Região** ( $C_{13}$ ): Para o cálculo desta característica, primeiro obtém-se a coordenada  $i$  do centro de massa da linha da região, em analogia com o centro de massa físico tem-se

$$i_{CM} = \frac{\sum_{i,j} i f[i, j]}{\sum_{i,j} f[i, j]} \quad (3.3.4)$$


A figura 3.3a ilustra uma região segmentada (nesse caso um defeito). Considerando-se que os eixos como mostrados na figura, pode-se obter através da equação 3.3.4 para este defeito segmentado na radiografia de um isolador polimérico, a curva ilustrada na figura 3.3b, que mostra a variação do centro de massa em relação à

cada linha na região segmentada, ou seja, em relação ao eixo Y (figura 3.3a). Obtém-se então, a derivada máxima desta curva para o valor da característica  $C_{13}$ .

$$C_{13} = \frac{di_{CM}}{dy} \quad (3.3.5)$$



(a)



(b)

Figura 3.3: Defeito (esquerda) e gráfico ilustrando a variação da coordenada X do centro de massa do defeito em relação ao eixo Y (direita).

### 3.4 GRADIENTE DE UMA IMAGEM

A essência da detecção de bordas está na operação de identificação de mudanças locais significativas na radiografia. O gradiente é o operador mais utilizado para diferenciação de imagens. Considere-se uma imagem  $f$  na posição  $(x, y)$ , o gradiente desta imagem será dado por

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (3.4.1)$$

A partir de análise vetorial, sabe-se que o vetor gradiente aponta na direção de mudança mais rápida de  $f$  na posição  $(x, y)$ . Em detecção de bordas, a magnitude desse vetor é uma medida importante, em geral, chamada simplesmente de gradiente e denotada  $\nabla f$ , em que

$$\nabla f = \text{mag}(\nabla f) = \sqrt{G_x^2 + G_y^2} \quad (3.4.2)$$

Normalmente, aproxima-se o gradiente com valores absolutos para facilitar a implementação, conforme

$$\nabla f \approx |G_x| + |G_y| \quad (3.4.3)$$

ou

$$\nabla f \approx \max(|G_x|, |G_y|) \quad (3.4.4)$$

### 3.5 MORFOLOGIA MATEMÁTICA

Operadores morfológicos são utilizados em um grande número de aplicações em processamento de imagens, incluindo a identificação de formas essenciais dos objetos (esqueletos), extração de componentes conexos, busca de padrões espaciais específicos, suavização de bordas e muitas outras [27].

A morfologia estuda as formas que a matéria pode assumir. O termo é derivado do grego: *morphê* (forma) e *logos* (ciência). Por exemplo, a morfologia vegetal estuda a estrutura dos organismos vegetais. Na língua portuguesa, a morfologia é a parte da gramática que estuda a estrutura das palavras [28]. Assim, a morfologia matemática leva em consideração modelos matemáticos. Portanto, os objetos de estudos serão estruturas matemáticas.

Quando se fala em estruturas, logo vem à mente qual tipo de matéria que esta estrutura trata. Uma imagem pode conter qualquer tipo de matéria. Por esta razão, a morfologia matemática pode ser aplicada em inúmeras áreas do conhecimento, por exemplo: biologia, medicina, engenharia, física, etc.

A morfologia matemática, formulada por Georges Matheron (1930 - 2000) e Jean Paul Frédéric Serra, na École des Mines de Paris, concentra-se no estudo das formas geométricas das entidades presentes numa imagem [27, 29, 30].

O princípio básico da morfologia matemática está em extrair informações relativas à geometria e à topologia de um conjunto desconhecido de uma imagem [27].

Pode-se dizer que o “poder” da morfologia matemática está centrado no chamado elemento estruturante. Este é um conjunto completamente definido e conhecido (forma e tamanho), que é comparado, a partir de uma transformação, ao conjunto desconhecido da imagem. O resultado dessa transformação permite avaliar o conjunto desconhecido. O formato e o tamanho do elemento estruturante possibilitam testar e quantificar de que maneira o elemento estruturante “está ou não contido” na imagem. A figura 3.4 ilustra uma imagem binária, um elemento estruturante e exemplos de interação. O tipo e a natureza da informação extraída dependem do tipo de elemento estruturante usado e do tipo da imagem analisada [27].




Figura 3.4: Exemplos de interação do elemento estruturante numa imagem binária.

A morfologia matemática pode ser aplicada tanto a imagens binárias quanto a imagens em níveis de

cinza. Há uma diferença de enfoque nos dois grupos. Em imagens binárias, na vizinha de cada *pixel* da imagem original é procurada uma configuração de pontos brancos e pretos. Na morfologia em níveis de cinza é necessário saber o valor do *pixel* mais escuro ( $L_{min}$ ) e o valor do *pixel* mais claro ( $L_{max}$ ). O valor do *pixel* resultante corresponde a uma combinação de  $L_{min}$  e  $L_{max}$ .

### 3.5.1 Operadores Morfológicos em Imagens Binárias

#### Dilatação binária ( $\oplus$ )

A dilatação, também as vezes chamada de dilação, é uma transformação morfológica que combina dois conjuntos usando adição vetorial.

$$A \oplus B = A \cup B = \{c | c = a + b, a \in A, b \in B\} \quad (3.5.1)$$

onde  $A$  representa a imagem sendo operada e  $B$  é um segundo conjunto onde é chamado elemento estrutural e sua composição define a natureza específica da dilatação [20]. A figura 3.5 ilustra um exemplo de dilatação binária. O *pixel* marcado com um “X” representa a origem (0, 0) de cada imagem.




Figura 3.5: Exemplo de dilatação numa imagem binária.

#### Erosão binária ( $\ominus$ )

A erosão da imagem  $A$  pelo elemento estruturante  $B$  pode ser definida como [20]:

$$A \ominus B = B \cap A = \{x | x + b \in A, \forall b \in B\} \quad (3.5.2)$$

A figura 3.6 ilustra um exemplo de erosão binária.

#### Abertura ( $\circ$ )

A abertura em geral suaviza o contorno de uma imagem, quebra estreitos e elimina proeminências delgadas. A operação de abertura é usada também para remover ruídos da imagem. A abertura de um conjunto  $A$  por elemento estruturante  $B$  é denotado  $A \circ B$  e definida conforme a seguinte equação:

$$A \circ B = (A \ominus B) \oplus B \quad (3.5.3)$$

A figura 3.7 ilustra um exemplo de abertura.






Figura 3.6: Exemplo de erosão numa imagem binária.




Figura 3.7: Exemplo de abertura numa imagem binária.

### Fechamento (•)

O fechamento funde pequenos quebras e alargas golfos estreitos, elimina pequenos orifícios. Se uma abertura cria pequenos vazios na imagem, um fechamento irá preencher ou fechar os vazios, estas operações podem remover muitos dos *pixels* brancos com ruídos, ou seja basicamente ele é igual a abertura só que primeiramente é feita a dilatação e após é feita a erosão assim ela se define como:

$$A \bullet B = (A \oplus B) \ominus B \quad (3.5.4)$$

A figura 3.8 ilustra um exemplo de fechamento.




Figura 3.8: Exemplo de fechamento numa imagem binária.

### 3.5.2 Operadores Morfológicos em Níveis de Cinza

#### Erosão e dilatação

Serra [29] mostrou que é possível relacionar a erosão com a subtração de Minkowski para funções:

**Definição 3.1** A erosão de um sinal  $f$  por um elemento estruturante  $g$  é:

$$ero^g(f(x)) = \text{Min}\{f(y) - g(x - y) : y \in E\} \quad (3.5.5)$$

onde a erosão não é definida num ponto onde o elemento estruturante não está abaixo do sinal  $f$ .

Os efeitos da erosão em níveis de cinza são o de escurecer a imagem, alargar os vales (padrões escuros), conectar vales próximos, reduzir picos (padrões claros) e separar picos próximos [27].

Serra [29] mostrou que é possível relacionar a dilatação com a adição de Minkowski para funções:

**Definição 3.2** A dilatação de um sinal  $f$  por um elemento estruturante  $g$  é:

$$dil^g(f(x)) = \text{Max}\{f(y) + g(x - y) : y \in E\} \quad (3.5.6)$$

Os efeitos da dilatação em níveis de cinza são o de clarear a imagem, alargar os picos, conectar picos próximos, reduzir vales e separar vales próximos [27].

#### Abertura e fechamento

As definições dada pelas equações 3.5.5 e 3.5.6 permitem o surgimento de novas operações, como as que serão definidas agora. Aqui denota-se  $\tilde{g}$  como o transposto do elemento estruturante  $g$ .

**Definição 3.3** A abertura de um sinal  $f$  por um elemento estruturante  $g$  é:

$$abe^g(f) = dil^g(ero^{\tilde{g}}(f)) = (f \ominus \tilde{g}) \oplus g \quad (3.5.7)$$

**Definição 3.4** O fechamento de um sinal  $f$  por um elemento estruturante  $g$  é:

$$fec^g(f) = ero^g(dil^{\tilde{g}}(f)) = (f \oplus \tilde{g}) \ominus g \quad (3.5.8)$$

#### Transformação *top-hat* e *bottom-hat*

As operações apresentadas a seguir auxiliam na detecção de picos e/ou vales no processamento de imagens.

Para a detecção de picos, a operação definida como *tophat* por abertura pode ser utilizada.

**Definição 3.5** O *tophat* por abertura de um sinal  $f$  por um elemento estruturante  $g$  é:

$$tophat_{abe}^g(f) = f - abe^g(f) \quad (3.5.9)$$

A figura 3.9 ilustra como a operação *top-hat* preserva os picos em uma imagem em níveis de cinza.

Analogamente, para a detecção de vales, a operação definida como *top-hat* por fechamento, ou também denominada operação *bottom-hat*, pode ser utilizada.




Figura 3.9: Operação *top-hat* em nível de cinza. Preserva os picos melhorando o contraste da imagem

**Definição 3.6** O *tophat por fechamento*, ou operação *bottom-hat*, de um sinal  $f$  por um elemento estruturante  $g$  é:

$$\text{tophat}_{fec}^g(f) = \text{fec}^g(f) - f \quad (3.5.10)$$

A figura 3.10 ilustra como a operação *bottom-hat* preserva os vales em uma imagem em níveis de cinza.




Figura 3.10: Operação *bottom-hat* em nível de cinza. Preserva os vales melhorando o contraste da imagem.

## Capítulo 4

# RECONHECIMENTO DE PADRÕES UTILIZANDO REDES NEURAIIS

Redes neurais, ou redes neurais artificiais, representam uma tecnologia que possui raiz multidisciplinar: neurociência, matemática, física, ciência da computação e engenharia.

Devido a sua habilidade de “aprender”, com ou sem “professor”, a partir de dados de entrada, elas encontram aplicações em diversos campos. Aqui elas foram utilizadas no reconhecimento de padrões.

O reconhecimento de padrões é formalmente definido como o processo pelo qual um padrão/sinal recebido é atribuído a uma classe dentre um número pré-determinado de classes (categorias) [2].

Neste capítulo, pretende-se abordar os principais conceitos referentes às redes neurais artificiais e sua aplicação no reconhecimento de padrões. Destaca-se, entretanto, que de forma alguma pretende-se abordar e discutir todos os aspectos e teorias sobre o assunto, tendo em vista a vasta literatura existente, como por exemplo, as referências utilizadas para a escrita deste capítulo: Haykin [2], Gonzalez [20], Fausett [31] e Duda e Hart[36].

### 4.1 PADRÕES E CLASSES

Um padrão de uma classe é uma descrição quantitativa ou estrutural de um objeto, ou de outra entidade de interesse, em uma imagem ou sinal [20]. Um padrão é, em geral, composto por um ou mais descritores conhecidos como características. Uma classe de padrões pode ser considerada como uma família de padrões que compartilhem algumas propriedades comuns.

O reconhecimento de padrões envolve técnicas para atribuição dos padrões às suas classes. Para se representar padrões utiliza-se normalmente a representação vetorial. Assim, um vetor que representa um padrão pode ser dado por

$$\vec{x} = (x_1, x_2, x_3, \dots, x_n) \quad (4.1.1)$$

onde  $x_i$  é a  $i$ -ésima característica, e  $n$  é o número de características.

## 4.2 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais surgiram em 1943 com o primeiro neurônio desenvolvido por Warren S. McCulloch e Walter Pitts, motivados pelo desejo de tentar compreender o cérebro e emular algumas de suas funções [32].

Existem vários pontos de vista da natureza de uma rede neural. Assume-se aqui a visão de que as redes neurais são basicamente modelos matemáticos de processamento de informação.

Segundo Fausett [31], uma rede neural artificial é um sistema de processamento de informação que possui certas características de desempenho semelhantes aos das redes neurais biológicas. Redes neurais artificiais têm sido desenvolvidas como generalizações de modelos matemáticos da cognição humana ou biologia neural considerando-se que:

- O processamento da informação ocorre em muitos elementos chamados neurônios.
- Os sinais são passados entre neurônios que estão conectados.
- Cada conexão tem um peso  $w$  associado, que é, numa rede neural típica, multiplicado pelo sinal transmitido.
- Cada neurônio aplica uma função de ativação (não - linear) para sua rede de entrada (soma dos sinais de entrada pesados) para determinar seu sinal de saída.

Aplicando ao tema de trabalho proposto para exemplificar: um sistema de inspeção radiográfica realiza uma tarefa de reconhecimento perceptivo, reconhecendo um dado tipo de defeito no isolador (bolhas ou trincas) em uma radiografia, baseado em um processo de *aprendizagem por experiência*.

O processo de aprendizagem é realizado por um algoritmo de aprendizagem, que tem como função modificar os pesos sinápticos da rede de forma ordenada.

Uma rede neural artificial é normalmente implementada utilizando componentes eletrônicos ou emulada via *software*.

Existem basicamente dois tipos de aprendizagem: (1) *aprendizagem supervisionada*, que envolve a modificação dos pesos sinápticos da rede pela aplicação de um conjunto de dados de treinamento (composto por entradas e suas respectivas saídas desejadas); (2) *aprendizagem não-supervisionada*, na qual não se dispõe de uma saída desejada e a própria rede irá se ajustar às regularidades estatísticas dos dados de entrada, desenvolvendo a capacidade de formar representações internas para codificar as características da entrada e, desta maneira, de criar automaticamente as classes [2].

### 4.2.1 Modelo de Um Neurônio

O neurônio é a unidade fundamental de uma rede neural. A figura 4.1 ilustra um modelo de um neurônio, base para elaboração de diversos tipo de arquitetura de redes neurais artificiais. Ele é composto normalmente dos seguintes elementos:

- Um conjunto de sinapses, cada qual tendo o seu próprio peso ou peso sináptico. Uma entrada  $x_n$ , conectada ao neurônio  $j$  através da sinapse  $w_{jn}$ , é multiplicada pelo peso sináptico  $w_{jn}$ . O índice  $j$  refere-se ao

neurônio em questão e o  $n$  se refere à entrada que o peso conecta. É importante ressaltar que um peso sináptico pode ter valores positivos ou negativos.

- Um somador que soma os sinais de entradas da rede ponderados pelos respectivos pesos sinápticos do neurônio, executando uma combinação linear dos mesmos com um sinal de polarização  $b_j$ .
- Uma função de ativação  $\phi(y_k)$  que é usada para restringir a amplitude da saída de um neurônio. Normalmente uma saída de um neurônio está contida no intervalo de  $[0,1]$ , para uma saída *binária*, ou  $[-1, 1]$ , para uma saída *polarizada*.

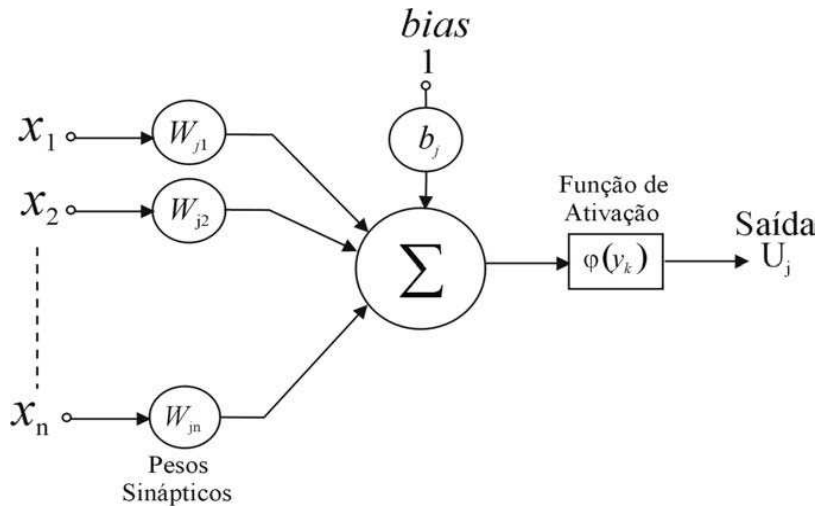


Figura 4.1: Modelo de um neurônio artificial [2].

O modelo apresentado na figura 4.1 inclui uma polarização (ou *bias*  $b_j$ ) aplicado ao neurônio que pode ser representado por uma sinapse conectada à uma porta de sinal fixa unitária. Este *bias* tem o efeito de aumentar ou diminuir a entrada da função de ativação, o que vai depender de ser ele positivo ou negativo.

Utilizando-se notação matemática, o neurônio  $j$  pode ser escrito

$$y_j = \sum_{i=1}^n w_{ji}x_i + b_j \quad (4.2.1)$$

e

$$U_j = \varphi(y_j) \quad (4.2.2)$$

onde  $x_1, x_2, \dots, x_n$  são as entradas do neurônio;  $w_{j1}, w_{j2}, \dots, w_{jn}$  são os pesos sinápticos do neurônio  $j$ ;  $y_j$  é a combinação linear das entradas e do *bias*  $b_j$  e  $\varphi(y_j)$  é a função de ativação [2].

Usualmente, três tipos de funções de ativação são utilizadas em redes neurais, segundo Haykin [2] e Fausett [31]: função de limiar, função de limiar por partes e função sigmóide. A função sigmóide, cujo gráfico tem forma de S, é a mais empregada na construção de redes neurais artificiais. Um função deste tipo que é muito utilizada é a função tangente hiperbólica, uma função deste tipo que é muito utilizada é a função tangente hiperbólica, definida por:

$$U = \varphi(y) = \tanh(y) \quad (4.2.3)$$

Esta função apresenta algumas vantagens de utilização [2] e entre elas se destaca a propriedade de ser diferenciável em todo domínio, fator importante para o treinamento em retropropagação do erro.

### 4.2.2 Perceptrons de Uma Camada

É conveniente visualizar neurônios como em arranjos de camadas [31].

Tipicamente, os *perceptrons* possuem três camadas de neurônios - unidades sensoras, associativas e de resposta - formando um modelo aproximado da retina [31]. Mas, inicialmente, considerar-se-á perceptrons de apenas uma camada.

A prova do teorema de aprendizagem do *perceptron* demonstrou que o mesmo poderia aprender qualquer coisa que ele pudesse representar. É importante diferenciar representação de aprendizagem. Representação refere-se à habilidade de um *perceptron* (ou qualquer outra rede) para simular uma função específica. Aprendizagem requer a existência de um procedimento sistemático para ajustar os pesos sinápticos à produzir uma função [2].

O *perceptron* é constituído por uma combinação linear das entradas  $x_1, x_2, \dots, x_n$  aplicada as suas sinapses  $w_1, w_2, \dots, w_n$ , e um *bias*  $b$  que é incorporado externamente. Quando o resultado desta operação é positivo, o neurônio produz uma saída  $+1$ , quando é negativo, a saída é  $-1$ , conforme a equação

$$y = \sum_{i=1}^n w_i x_i + b \quad (4.2.4)$$

Na equação acima, se  $y > 0 \implies U = +1$  e caso contrário  $y < 0 \implies U = -1$ .

O objetivo do *perceptron* é classificar corretamente o conjunto de estímulos aplicados externamente  $x_1, x_2, \dots, x_n$  em uma de duas classes  $C_1$  ou  $C_2$ . A regra de decisão para classificação é atribuir o ponto representado pelas entradas  $x_1, x_2, \dots, x_n$  à classe  $C_1$ , se a saída do *perceptron* for  $+1$ , e à classe  $C_2$  se ela for  $-1$ .

Para que se compreenda melhor o comportamento de um classificador de padrões, geralmente traça-se um mapa das regiões de decisão no espaço de sinal  $n$ -dimensional abrangido pelas  $n$  variáveis de entrada  $x_1, x_2, \dots, x_n$ . Na forma mais simples do *perceptron*, existem duas regiões separadas por um hiperplano definido por [2]:

$$\sum_{i=1}^n w_i x_i + b = 0 \quad (4.2.5)$$

A figura 4.2 ilustra o que acontece para o caso de duas variáveis  $x_1$  e  $x_2$ . Nesta situação, a fronteira de decisão toma forma de uma reta. Então, um ponto  $(x_1, x_2)$  que se encontra de um lado da linha de fronteira é atribuído à classe  $C_1$ , e um ponto  $(x_1, x_2)$  que está do outro lado da linha de fronteira, à classe  $C_2$ . É importante notar que a função do *bias*  $b$  é simplesmente deslocar a fronteira de decisão em relação à origem.

Para que um *perceptron* funcione adequadamente, as duas classes  $C_1$  e  $C_2$  devem ser linearmente separáveis. Então, padrões a serem classificados devem estar suficientemente separados entre si para garantir que a superfície de decisão consista de um hiperplano.

### 4.2.3 Perceptrons de Múltiplas Camadas

As redes de múltiplas camadas de neurônios “com alimentação adiante”, ou *feedforward*, ou sem realimentação, formam uma classe importante de redes neurais. Basicamente, estas redes consistem de uma camada de




Figura 4.2: Ilustração do hiperplano (aqui, uma reta) como fronteira de decisão para um problema de classificação linear de padrões bidimensional de duas classes [2].

entrada (Haykin [2] denomina de nós sensoriais) e uma ou mais camadas intermediárias (Haykin [2] denomina de nós computacionais). Neste tipo de rede, as entradas se propagam apenas para a frente, camada por camada. São também conhecidas como perceptrons de múltiplas camadas, sendo uma generalização do perceptron de camada única.

Os perceptrons de múltiplas camadas vêm sendo utilizados para solução de diversos tipos de problemas. O treinamento destas redes é do tipo supervisionado e o algoritmo mais empregado é o de retropropagação do erro (do inglês *error backpropagation*) baseado na regra de aprendizagem por correção de erro [2].

A aprendizagem por retropropagação de erro consiste, resumidamente, de duas etapas: um passo para frente, a propagação do sinal, e um passo para trás, a retropropagação do erro. Um vetor de entrada é fornecido à camada de entrada da rede e seu efeito se propaga através da rede, camada por camada. Ao final da rede, um conjunto de saídas é produzido como resposta real da rede. Na etapa de propagação, os pesos sinápticos são mantidos fixos. Após esta etapa, a saída da rede é subtraída da saída desejada, produzindo um erro que é então retropropagado através da rede linearizada, sendo os pesos sinápticos ajustados de acordo com uma regra de correção de erro. O objetivo é aproximar ao máximo possível a saída real da rede da saída desejada, minimizando o erro.

A figura 4.3 ilustra a arquitetura de um perceptron de múltiplas camadas com duas camadas (uma camada intermediária/oculta e uma camada de saída) e totalmente conectada.

### Algoritmo de Retropropagação do Erro

O erro calculado na saída do neurônio  $j$ , no passo  $n$  de iteração (quando é apresentado o  $n$ -ésimo exemplo de treinamento), é assim definido:

$$E_j(n) = d_j(n) - U_j \quad (4.2.6)$$






Figura 4.3: Arquitetura de uma rede múltipla camada com uma camada intermediária e uma camada de saída [2].

O valor no instante  $n$  da “energia” do erro é definido para o neurônio  $j$  conforme [2]:

$$\frac{1}{2}e_j^2(n) \quad (4.2.7)$$

Para sabermos a energia total  $E(n)$  do erro, basta somar todos os termos  $1/2e_j^2(n)$  de todos os neurônios da camada de saída. Então podemos escrever:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.2.8)$$

Neste caso,  $C$  representa todos os neurônios da camada de saída da rede. Como  $n$  representa o número total de padrões contidos no conjunto de treinamento, a energia média do erro quadrado é calculada somando-se os  $E(n)$  para todos os  $n$  e depois dividindo o resultado por  $n$ , temos então:

$$\bar{E}(n) = \frac{1}{n} \sum_{i=1}^n E(i) \quad (4.2.9)$$

A energia média,  $\bar{E}(n)$ , representa a função de custo como uma medida do desempenho do processo de aprendizagem da rede. O objetivo do processo de aprendizagem por retropropagação é ajustar os parâmetros livres da rede (pesos sinápticos e *bias*) para minimizar  $\bar{E}(n)$ .

Em resumo, um algoritmo de retropropagação do erro pode ser descrito pelos seguintes passos:

1. Iniciar os pesos sinápticos, *bias* e parâmetros da rede
2. Repetir até que um critério de parada previamente estabelecido seja atingindo (erro mínimo, número de épocas, etc.). Para cada padrão de treinamento:
  - 2.1 Calcular a saída da rede na fase de propagação.
  - 2.2 Comparar as saídas produzidas com as saídas desejadas.
  - 2.3 Atualizar os pesos sinápticos através da fase de retropropagação e equações descritas.

O algoritmo de retropropagação do erro apresenta algumas desvantagens, como: lentidão de treinamento para superfícies de erros mais complexas e convergência para mínimos locais. Por este motivo, existem várias técnicas

alternativas de treinamento que são usadas nos dias de hoje para solução destes problemas, como a utilização de momento,  $\eta$ , variável, etc

### 4.3 COMPONENTES PRINCIPAIS DE DISCRIMINAÇÃO

A técnica de análise das componentes principais (PCA) é amplamente conhecida como uma das técnicas mais utilizadas para redução da dimensionalidade de um conjunto de dados multivariáveis. Originalmente [2], é uma técnica de mapeamento linear de dados multidimensionais em um número menor de componentes, minimizando a perda de informação. Entretanto, por ser um método linear de mapeamento, se torna inadequado em muitos problemas de engenharia que são não-lineares, pois as componentes de ordem menor podem conter informações importantes e que portanto não devem ser descartadas [1]. Por este motivo, recorre-se a análise das componentes principais não-lineares [1]. Uma das maneiras de se desenvolver as componentes principais é utilizando as redes neurais artificiais, conforme descreve Haykin [2] para o caso de auto representação. Neste caso, elas podem ser usadas tanto para redução das componentes de representação, quanto para discriminação de classes de padrões, a partir da projeção do espaço original de dados na base de componentes principais. No presente trabalho, recorre-se às componentes principais para discriminação não-linear, implementadas com as redes neurais, sendo estas desenvolvidas com o algoritmo de retropropagação do erro.

## Capítulo 5

# MATERIAIS E EQUIPAMENTOS

### 5.1 AMOSTRAS DE ISOLADORES DE POLIMÉRICOS

O isolador polimérico (ver figura 5.1) é utilizado em redes de distribuição de energia elétrica com cabos nus ou cobertos, classe de tensão 15 kV. É fabricado em polietileno de alta densidade (HDPE - *High Density Polyethylene*) na cor cinza, massa em torno de 500 g e foi desenvolvido exclusivamente para se obter excelentes características mecânicas e atender aos requisitos de resistência aos raios ultravioleta, ao trilhamento elétrico e às intempéries exigidos neste tipo de rede.



Figura 5.1: Isolador polimérico classe 15 kV na linha de distribuição.

As amostras de isoladores poliméricos classe 15 kV, utilizados neste trabalho, podem ser visualizadas na figura 5.2. Utilizou-se 52 amostras de 5 fabricantes diferentes (fabricante A, B, C, D e E).




Figura 5.2: Amostras de isoladores poliméricos classe 15 kV utilizadas.

## 5.2 SISTEMA CT2000

O SISTEMA CT2000 (mostrado na figura 5.3) é um equipamento industrial de raios X, que é utilizado para a obtenção radiografias e/ou tomografias de materiais.




Figura 5.3: SISTEMA CT2000 (figura fora de escala).

O SISTEMA CT2000 é composto conforme segue:

- Gerador de raios X
  - ↪ Minifoco de  $0.4 \times 0.4 \text{ mm}^2$
  - ↪ Alvo de tungstênio
  - ↪ Faixa de tensão: 10 a 160 kV
  - ↪ Faixa de corrente: 0 a 10 mA
- Intensificador de Imagens
- Câmera CCD
  - ↪ Dimensão espacial da imagem:  $640 \times 480 \text{ pixels}$

↪ Resolução em profundidade (saída digital): 8 bits

- Unidade de Controle
- Computador

Este sistema possui uma mesa giratória controlada pelo computador para a obtenção de tomografias. Aqui, esta mesa foi utilizada para se obter quatro radiografias de cada amostra (tomadas a cada  $45^0$ ). A aquisição das imagens foi realizada através de um intensificador de imagens acoplado a uma câmera CCD. O sinal da câmera é capturado por uma placa de vídeo montada no computador do sistema, o qual armazena as radiografias no padrão *Bitmap* (em imagens de 8 bits).

A figura 5.4 mostra a radiografia de um isolador obtida com o sistema CT2000. A tensão e a corrente utilizadas para a obtenção dessa imagem foram de 70 kV e 3mA, respectivamente.




Figura 5.4: Radiografia isolador polimérico (fabricante E, 70 kV e 3 mA).

### 5.3 SISTEMA RDP

Além do SISTEMA CT2000, outro sistema de radiografia digital foi utilizado. A figura 5.5 ilustra o Sistema de Radiografia Digital Portátil (SISTEMA RDP). Este sistema teve a sua montagem (a qual será tratada com maiores detalhes no próximo capítulo) concebida no projeto desta dissertação de mestrado e tem como aspecto principal a sua portabilidade, o que o torna útil em inspeções dos isoladores em campo, além de outro fator importante, uma resolução de imagem superior ao do SISTEMA CT2000. É composto conforme segue:

- Gerador de raios X (figura 5.6)
  - ↪ Modelo: PXS5-722SA (Kevex X-Ray Inc.)
  - ↪ Tamanho do foco:  $10\mu \times 10\mu \text{ m}^2$
  - ↪ Alvo de tungstênio




Figura 5.5: SISTEMA RDP (figura fora de escala).

- ↪ Faixa de tensão: 20 a 70 kV
- ↪ Faixa de corrente: 0 a 0.1 mA
- ↪ Material da janela, diâmetro e espessura: Berílio, 9.4 mm e 0.13 mm
- ↪ Grau de iluminação do cone de raios X: 34 graus
- ↪ Alimentação do tubo: 12 V DC
- ↪ Massa: 3.2 kg
- Detector de raios X (figura 5.5)
  - ↪ Modelo: HAMAMATSU CT7942
  - ↪ Dimensão espacial da imagem: 2400 x 2400 *pixels*
  - ↪ Resolução em profundidade (saída digital): 12 bits
  - ↪ Dinâmica das imagens coletadas: 9 frames/s (4 x 4 binning)
- Placa de Aquisição (*framegrabber*)
  - ↪ Modelo: NI/IMAQ PCI1422
- Unidade de Controle

- Computador




Figura 5.6: Fonte de raios X microfoco portátil do SISTEMA RDP.

A figura 5.7 ilustra uma imagem radiográfica de um isolador polimérico (amostra E) obtida com o SISTEMA RDP (70 kV,  $100\mu\text{A}$  e integração de 3 s). Neste isolador existe um grande defeito (região mais clara dentro do objeto acima da linha horizontal preta na figura 5.7).




Figura 5.7: Radiografia do isolador polimérico obtida com o SISTEMA RDP (70 kV,  $100\mu\text{A}$ , 3 s de integração).

A tabela 5.1 compara algumas características dos dois sistemas de radiografia citados.

## 5.4 INSTRUMENTAÇÃO PARA COMPOSIÇÃO DO SISTEMA RDP

Neste capítulo descreve-se a instrumentação eletrônica utilizada para a montagem do SISTEMA RDP. Esta abrangeu: (i) O controle e a alimentação da fonte portátil de raio X ; (ii) a alimentação do detector portátil de raios X (*Flat Panel*); (iii) o controle do sistema de integração (*Trigger*); (iv) a composição do sistema como um todo (*hardware e software*).

Tabela 5.1: COMPARAÇÕES ENTRE O SISTEMA CT2000 E SISTEMA RDP.

Item	SISTEMA CT2000	SISTEMA RDP
Tamanho do Foco	Minifoco 0.4 x 0.4 mm <sup>2</sup>	Microfoco 10 x 10 μm <sup>2</sup>
Janela	Be	Be (125 μm)
Alvo	W	W
Faixa de Tensão	10 a 160 kV	20 a 70 kV
Faixa de Corrente	0 a 10 mA	0 a 0,1 mA
Resolução espacial	640 x 480 pixels	2400 x 2400 pixels
Binning	Não	Sim (2x2, 4x4)
Trigger	Não	Sim (Int e Ext)
Tamanho do Pixel	290 μm	50 μm
Saída Digital	8 bits	12 bits

### 5.4.1 Controle e Alimentação do Gerador Portátil de Raios X

O gerador portátil de raios X do Sistema RDP é alimentado por tensão contínua 12 V DC com consumo nominal de 1.2 A.

A tensão e a corrente são ajustadas por meio de 2 potenciômetros de 1 kΩ/1W montados no painel. O potenciômetro de ajuste de tensão gera um sinal de 0 ~ 3.5V que corresponde à tensão aplicada ao tubo de raios X de 0 ~ 70 kV. O potenciômetro de ajuste de corrente gera um sinal de 0 ~ 2.5 V que corresponde a corrente entre o ânodo e cátodo do tubo na faixa de 0 ~ 0.1 mA.

O gerador envia sinais de tensão nas faixas mencionadas acima relativas à tensão e corrente real no tubo. Estes valores são indicados em voltímetros digitais que ficam no painel de controle, os quais foram calibrados para a correta indicação de corrente e tensão no tubo.

Toda a interface gerador-controle/gerador-alimentação é feita através de 12 pinos (ver figura 5.9) conectados por cabos ao controle que fica em um *rack* junto ao computador do sistema e à bateria de alimentação (ver figura 5.10). Estes possuem 12 m para tornar possível as inspeções dos isoladores instalados nos postes, ou seja, posicionar tanto a fonte quanto o detector de raios X próximo ao isolador sem retirá-lo do poste.



Figura 5.8: Vista frontal, computador e controle do tubo de raios X do SISTEMA RDP.

Um carregador de baterias também foi montado. O diagrama na figura 5.11 ilustra o circuito utilizado.



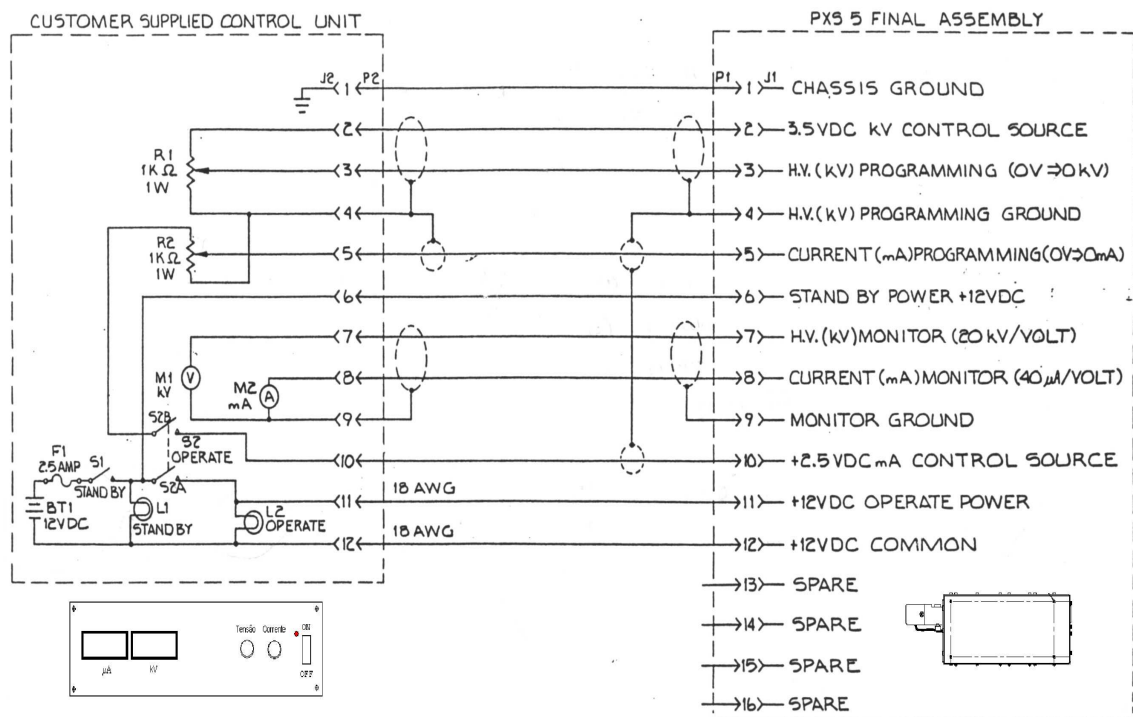


Figura 5.9: Esquema para controle do tubo de raios X do Sistema RDP.




Figura 5.10: Rack portátil com o controle da fonte de raios X do Sistema RDP e o computador do sistema.

## 5.4.2 Alimentação do Módulo de Imagem

O módulo de imagens do SISTEMA RDP (*Flat Panel*) requer três tipos de fontes de alimentação (conforme especificações do equipamento adquirido), as quais são +5 V analógica, +5 V digital e uma fonte simétrica

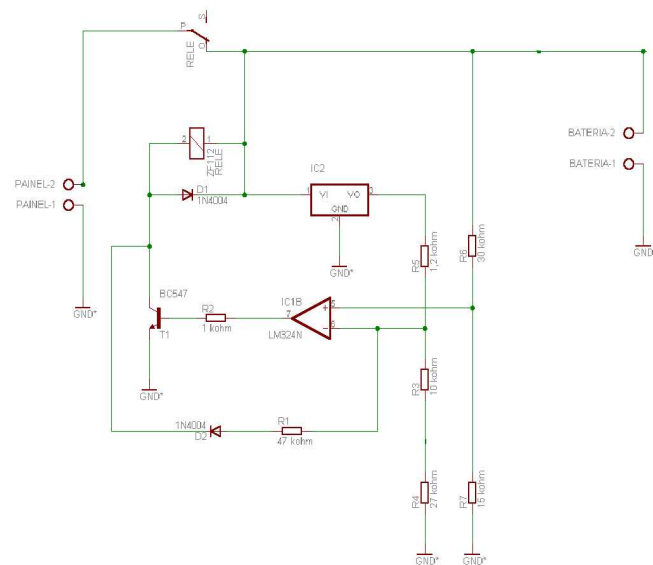


Figura 5.11: Diagrama ilustrando o circuito utilizado para a montagem do carregador de baterias.

de  $\pm 7.5$  V. A tabela 5.2 mostra para cada fonte a taxa máxima de corrente. A figura 5.12a mostra as fontes de alimentação do *Flat Panel*. Estas estão numa pequena caixa de alumínio conectadas ao *rack* do sistema por um cabo de 12 m. Os transformadores destas fontes ficam dentro do controle do gerador de raios X mostrado na figura 5.8.

Tabela 5.2: TAXA DE CORRENTE MÁXIMA NAS FONTES DO MÓDULO DE IMAGEM.

Fontes	Taxa máxima de corrente (mA)
+7.5 V	100
-7.5 V	-100
A+5 V	700
D+5	1000

A figura 5.13 ilustra o diagrama do circuito utilizado para a construção das fontes do módulo de imagens do SISTEMA RDP.

### 5.4.3 Controle do *Trigger*

Como visto anteriormente, o detector de raios X utilizado no SISTEMA RDP possui um modo de aquisição (modo integração) que permite ativá-lo por um *trigger* externo. Isto é útil porque pode-se trabalhar com baixas energias no tubo de raios X (o que aumenta o contraste da imagem) controlando-se o tempo de integração na CCD do “Flat”. Como esse detector possui uma interface com um computador, utilizou-se para controle do *trigger* uma porta serial do tipo RS 232C, com conector tipo DB9 (figura 5.12b), deste computador. Controla-se assim, por meio de um *software*, o tempo de integração em até 1/10 s de precisão, limite este imposto pela IDE utilizada.

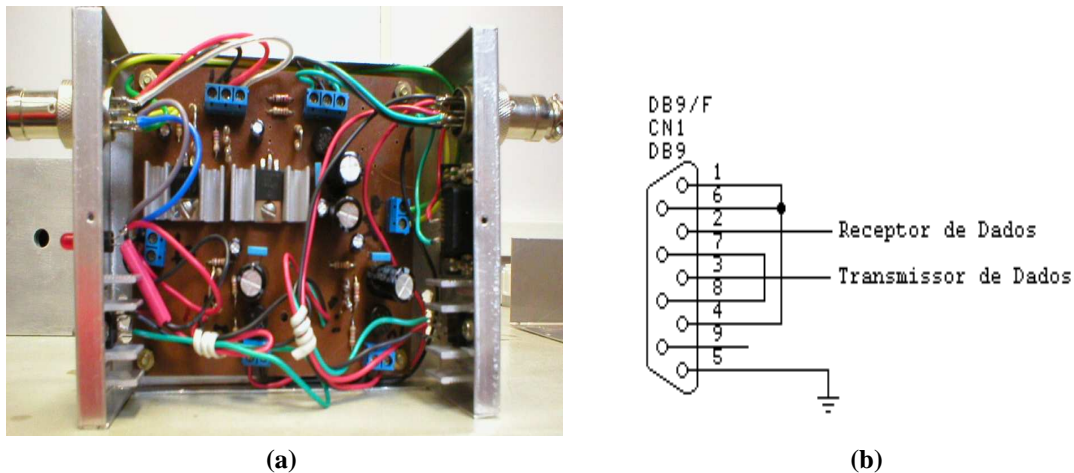


Figura 5.12: (a) Fontes montadas para alimentação do módulo de imagens. (b) Conector serial RS 232C, tipo DB9.

Uma porta serial pode ser conectada com apenas 2 pinos, em uma conexão unidirecional. Em qualquer aplicação prática, como esta aqui, é necessário utilizar circuitos que convertam níveis TTL para os exigidos pela interface [33]. O interfaceamento *PC-Flat* de raios X está sendo realizado com um cabo de 12 m.

As portas seriais no PC são totalmente programáveis. Pode-se transmitir caracteres com 5, 6, 7 ou 8 bits. O coração da interface serial é o circuito 8250, que permite o uso de funções como CTS (*clear to send*) entre outras.

Uma saída RS 232C inativa fica transmitindo  $-12$  V, controle OFF. Então a tensão pico-a-pico medida em um osciloscópio para um pulso dado nesta saída deve ser de 24 V. A figura 5.14a mostra a medida para um intervalo de dois sinais enviados do PC por um cabo de 12 m. Nesta mesma figura estão presentes os sinais de saída que chegam ao flat para controle do trigger. Pode-se ver, a partir desta figura, que o sinal enviado possui 17 V de tensão tomada numa medida pico-a-pico, ou seja, o cabo causou a atenuação do sinal enviado.


A figura 5.14b ilustra o circuito utilizado para a conversão do sinal transmitido do computador pela RS 232C. A figura 5.14b mostra a forma do sinal de entrada no circuito ilustrado na figura 5.14 e a forma do sinal de saída que chega até o detector de raios X para um tempo de integração de 2 s.

## 5.5 CONFIGURAÇÃO DO SISTEMA COMPUTACIONAL

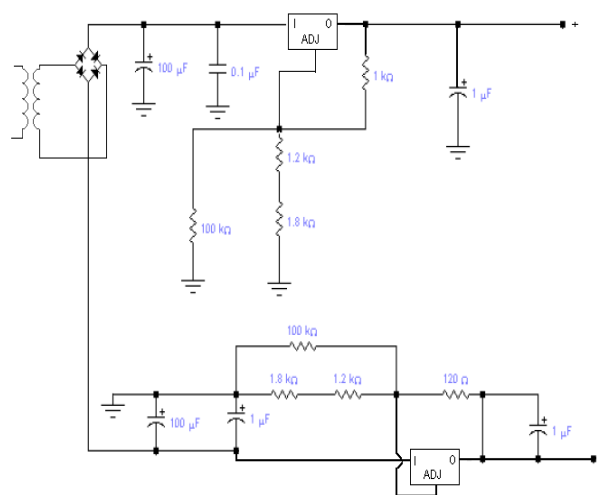
As características do computador utilizado para o processamento digital das imagens são listadas abaixo:

- Computador: Intel(R) Pentium
- Processador: Pentium 4 (1,8 GHz)
- Memória RAM: 256 MB
- Disco rígido: Maxtor (25 GB)

Um protótipo de uma interface computacional, denominado XDetector (ver figura 5.15a), foi desenvolvido em MATLAB com o *toolbox* de Processamento de Imagens e o GUIDE (*GUI Design Environment*), para se



(a)




(b)

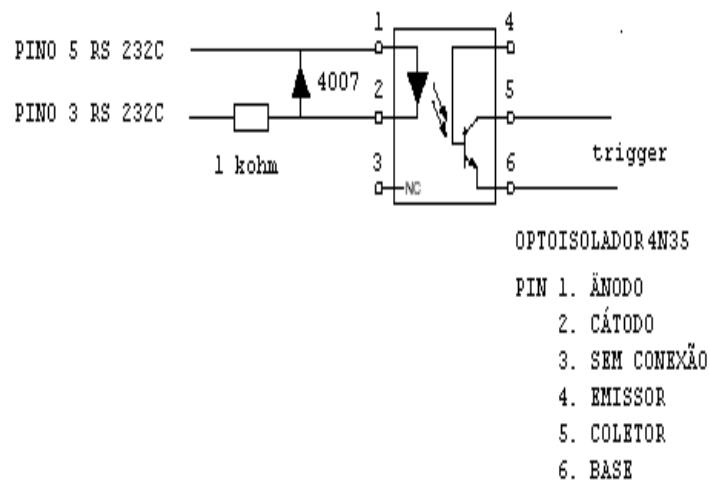
Figura 5.13: Diagrama fontes de alimentação do *Flat Panel*: (a) Fonte 5 V e (b)  $\pm 7.5$  V.

ter um programa que possua uma interface com o usuário durante o processamento digital das imagens adquiridas pelo SISTEMA CT2000. As opções Características e Classificação no futuro serão habilitadas com a união com o software utilizado para a classificação desenvolvida na COPPE/UFRJ (ver figura 5.15b) também desenvolvida em MATLAB, com a *toolbox* de Redes Neurais. O XDetector tem como opção a segmentação manual (apenas uma imagem) ou automática (várias imagens em um diretório) com a gravação das imagens de cada etapa e os dados com as características de cada região em um arquivo ASCII formato texto com colunas separadas por vírgulas.

Para a aquisição (apena está opção está implementa ainda) das imagens do SISTEMA RDP foi desenvolvido uma interface em Visual Basic [35].




(a)

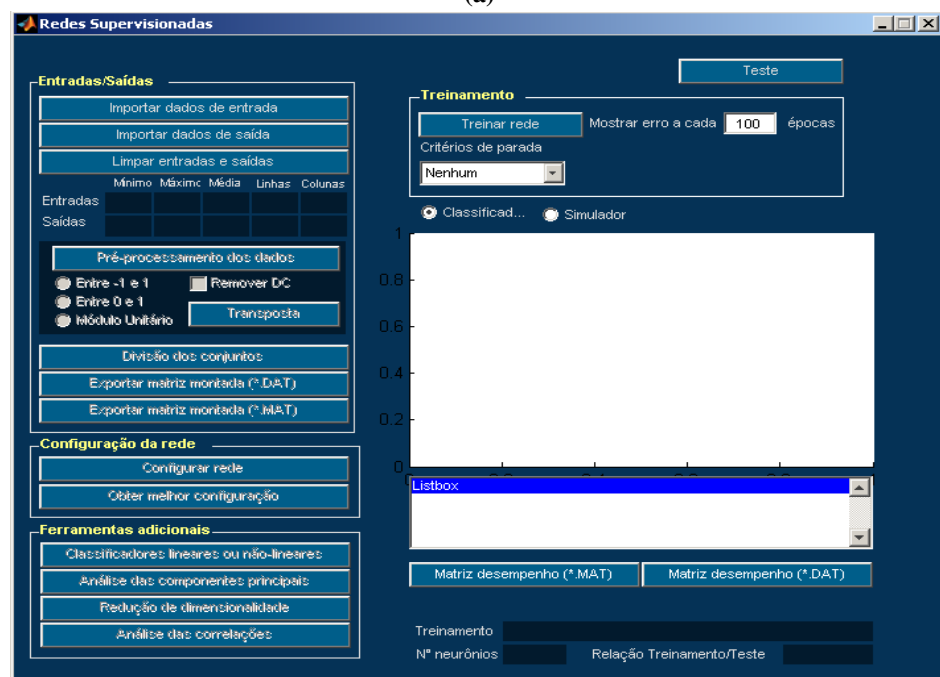


(b)

Figura 5.14: Modo de integração (Trigger): (a) Circuito utilizado para o *Trigger*. O sinal é enviado pelo computador através do pino 3 e 5 da RS232C. (b) Pulsos do sinal de entrada e saída do *Trigger* no circuito da figura 5.14a.



(a)



(b)

Figura 5.15: GUIs (*Guide User Interfaces*) utilizada para a interface com o usuário desenvolvida em MATLAB: (a) Protótipo XDetector (b) Programa para treinamento da rede neural (COPPE/UFRJ).

## Capítulo 6

# METODOLOGIA EXPERIMENTAL

O fluxograma, na figura 6.1, ilustra as metodologias utilizadas neste trabalho para o Processamento Digital de Imagens Radiográficas (PDIR). As seções seguintes descrevem cada etapa do fluxograma aplicada à detecção de defeitos em radiografias de isoladores poliméricos.

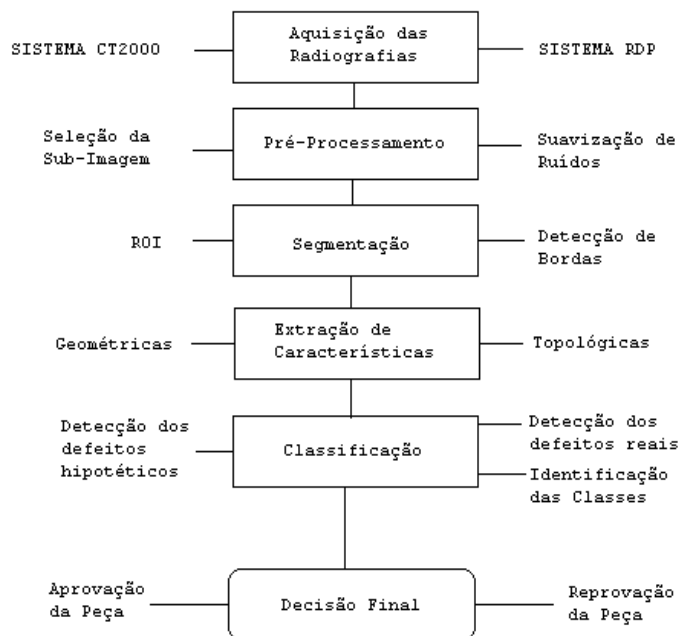


Figura 6.1: Fluxograma mostrando as etapas de PDIR realizadas neste trabalho.

## 6.1 AQUISIÇÃO DAS RADIOGRAFIAS

Inicialmente, para a validação das metodologias utilizadas e porque não havia ainda o sistema portátil, devido à espera dos componentes do exterior, utilizou-se as imagens adquiridas com o SISTEMA CT2000 para as etapas de PDIR. A tensão e a corrente utilizadas no tubo de raios X para as imagens radiográficas obtidas de todas as amostras no SISTEMA CT2000 foram de 70 kV e 3 mA, respectivamente.

As 52 amostras de isoladores ensaiadas resultaram num banco de dados de 208 imagens, pois foram feitas 4 radiografias de cada amostra em ângulos de  $0^0$ ,  $45^0$ ,  $90^0$  e  $135^0$ , utilizando-se a mesa giratória do SISTEMA CT2000. A proposta é automatizar o sistema de inspeção, assim é importante que ele seja capaz de analisar imagens independente da rotação que o objeto possua, o que ocorreria numa linha de produção de isoladores, por exemplo. Para salientar isso, e também para aumentar o número de regiões segmentadas, o que implica no melhoramento quantitativo dos dados na rede de treinamento, optou-se por fazer as 4 radiografias de cada amostra dos isoladores analisados. Como exemplo, a figura 6.2 ilustra as radiografias obtidas para uma amostra do fabricante E. Considera-se a primeira radiografia em  $0^0$ . As próximas estarão em 45, 90 e 135 graus.




Figura 6.2: Aquisição das Radiografias com o SISTEMA CT2000 (70 kV, 3 mA, fabricante E).



## 6.2 PRÉ-PROCESSAMENTO

O pré-processamento das imagens ocorre em duas etapas. Na primeira etapa, através de coordenadas pré-definidas, obtém-se uma sub-imagem da imagem original. A vantagem deste procedimento é o de manipular uma imagem menor e, uma vez que os defeitos ocorrem geralmente na “cabeça” do isolador, não há necessidade de analisar a imagem inteira, o que favorece também o custo computacional.

Na segunda etapa, após obter-se a sub-imagem, aplica-se um filtro passa-baixa para reduzir possíveis ruídos presentes na imagem. A matriz abaixo mostra a forma da máscara 5x5 do filtro Gaussiano (*kernel* Gaussiano) utilizado para convolução com a sub-imagem extraída. Os valores dos elementos da matriz indicam a amplitude do filtro.

$$\begin{bmatrix} 0 & 1/32 & 1/16 & 1/32 & 0 \\ 1/32 & 1/32 & 1/16 & 1/32 & 1/32 \\ 1/16 & 1/16 & 1/8 & 1/16 & 1/16 \\ 1/32 & 1/32 & 1/16 & 1/32 & 1/32 \\ 0 & 1/32 & 1/16 & 1/32 & 0 \end{bmatrix}$$

A figura 6.3 mostra as imagens finais obtidas após a operação do pré-processamento nas imagens da figura 6.2.




Figura 6.3: Sub-imagens obtidas a partir das radiografias originais na figura 6.2. Utilizou-se um filtro gaussiano nestas imagens.

## 6.3 SEGMENTAÇÃO

Os métodos de segmentação utilizados tiveram como principais objetivos a extração da região de interesse (ROI) e a segmentação dos defeitos reais e hipotéticos nas imagens analisadas.

### 6.3.1 Extração da Região de Interesse - ROI

A segmentação da ROI é feita pela seleção dos *pixels* com alto gradiente. Frew *et al* [34] extraíram objetos de imagens realizando as seguintes etapas:

1. Suavização da imagem




Figura 6.4: Histograma dos valores resultantes do passo 3 no método de detecção da ROI.

2. Cálculo do gradiente da imagem utilizando a máscara:  $0.4 * \begin{bmatrix} 0 & 1/2 * i & 0 \\ 1/2 & 0 & -1/2 \\ 0 & -1/2 * i & 0 \end{bmatrix}$
3. Geração de um vetor dos valores do gradiente para facilitar o uso num histograma
4. Cálculo do histograma dos valores resultantes do passo 3 (ver figura 6.4)
5. Achar, a partir dos valores resultantes do passo 3, o valor de 0.01% do gradiente calculado
6. Determinação do grupo de *pixels* com gradientes elevados a partir do passo 5, ou seja, todos os valores maiores que os obtidos em 5
7. Cálculo de um limiar médio a partir do grupo obtido no passo 6
8. Limiarização da imagem a partir do resultado obtido em 7.

A figura 6.5B ilustra o resultado obtido a partir da sequência citada acima. Pode-se então obter a ROI (figura 6.5C) a partir do produto da imagem da figura 6.5A pela imagem da figura 6.5B.




Figura 6.5: (a) Imagem filtrada extraída a partir de coordenadas pré-definidas. (b) Inverso da imagem obtida pela limiarização a partir de *pixels* de alto gradiente. (c) ROI = (a)x(b).

As imagens na figura 6.6 mostram os resultados obtido para a segmentação da ROI para as radiografias da figura 6.3, como exemplo. Os *pixels* que não pertencem ao isolador possuem valor 0 (preto) e o isolador (o objeto de interesse) é uma imagem monocromática (com 256 níveis de cinza para estas imagens). Desta forma, é esta imagem (contendo a ROI) que segue para a etapa de segmentação de defeitos reais e hipotéticos.




Figura 6.6: Identificação da ROI.

### 6.3.2 Segmentação dos Defeitos Reais e Hipotéticos

A seqüência de operações morfológicas utilizadas no algoritmo para segmentar os defeitos reais e hipotéticos nas imagens radiográficas analisadas é descrita a seguir.

A imagem contendo a ROI é lida. Denomina-se aqui está imagem de  $I_{entrada}$ . Dois elementos estruturantes são definidos para as operações: SE1 (formato disco, raio= 15) e SE2 (3x3). Estes elementos foram escolhidos por apresentarem melhores resultados após comparação com outras formas de elementos estruturantes testados. Em seguida, a abertura *top-hat* e a operação *bottom-hat* de  $I_{entrada}$  é realizada utilizando o elemento estruturante SE1, gerando as novas imagens  $I_{top}$  e  $I_{bot}$  (figura 6.7), respectivamente. Soma-se, então,  $I_{top}$  com  $I_{entrada}$  e, em seguida, subtrai-se o resultado de  $I_{bot}$ , tem-se então  $I_{enhance}$  (figura 6.7). Isto realça os vales (regiões escuras) entre os objetos. Calcula-se em seguida o complemento desta imagem,  $I_{ec}$  (figura 6.7) e a transformada estendida-mínima,  $I_{emin}$  (figura 6.7) de  $I_{ec}$ , que é a mínima regional da transformada H-mínima, para H escalar não negativo, igual a 11, conforme mostra linha de comando utilizada no MATLAB abaixo

```
Iemin = imextendedmin(Iec,11);
```

que é a mínima regional da transformada H-mínima (H é um escalar não negativo). Mínimas regionais são componentes conectados de *pixels* com o mesmo valor de intensidade,  $t$ , cujos todos os *pixels* do contorno externo têm um valor maior que  $t$  [30].

Um exemplo para a transformada H-mínima pode ser visto abaixo. Considere a matriz  $M1$  seguinte com duas mínimas regionais.

$$M1 = \begin{bmatrix} 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 7 & 7 & 7 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 7 & 7 & 7 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 7 & 7 & 7 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 6 & 6 & 6 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 6 & 6 & 6 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 6 & 6 & 6 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \end{bmatrix}$$

Suprime-se todas as mínimas para um valor específico (por exemplo, 4). Note-se como a região com o pixel valor 7 desaparece quando aplicamos a transformada em M1 ( $M2 = \text{imhmin}(M1, 4)$  ;).

$$M2 = \begin{bmatrix} 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 6 & 6 & 6 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 6 & 6 & 6 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 6 & 6 & 6 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 & 10 \end{bmatrix}$$

Após a transformada h-mínima realiza-se uma abertura de Iemin com SE2 para garantir que as bordas do isolador não sejam consideradas como defeitos hipotéticos, assim, esta última operação faz desaparecer o perfil externo do isolador gerando Idet. Os resultados da segmentação para as imagens na figura 6.6 podem ser vistas na figura 6.8.

## 6.4 EXTRAÇÃO DAS CARACTERÍSTICAS

A partir da imagem binária obtida com a segmentação dos defeitos reais e hipotéticos é possível calcular as propriedades geométricas e topológicas das regiões segmentadas (regiões brancas nas imagens da figura 6.8 com vizinhança 8 *pixels*).

Como exemplo da forma dos dados que se obtém a partir das regiões segmentadas, as tabelas 6.1 e 6.2 mostram um grupo das características obtidas para a imagem mostrada na figura 6.8 em  $0^0$ . As características geométricas são calculadas diretamente da imagem segmentada (imagem binária) e as topológicas a partir desta para se obter as coordenadas na imagem da figura 6.3 (imagem monocromática), conforme descrito no capítulo 3.




Figura 6.7: Resultados do algoritmo de segmentação de defeitos reais e hipotéticos.




Figura 6.8: Defeitos reais e hipotéticos segmentados.

## 6.5 CLASSIFICAÇÃO

Neste trabalho, dispendo-se de conjuntos de padrões de treinamento obtidos pelos cálculos das características das regiões segmentadas nas radiografias dos isoladores, recorreu-se às redes neurais tipo *feedforward* com algoritmo de treinamento supervisionado por retropropagação do erro para implementação dos classificadores [1].

Como a rede utilizada tem aprendizado supervisionado, após inspeção visual humana é necessário indicar nos dados obtidos, através do cálculo das características das regiões segmentadas, quais regiões são defeitos (D) e quais regiões são estruturas regulares (ER). Na matriz de dados contendo as características insere-se mais uma coluna onde os valores serão +1 para D ou -1 para ER, pois a rede de treinamento é polarizada. Aqui entra o trabalho de inspeção humana, que requer experiência para se apontar o que é defeito real nas radiografias e o que não é. Assim, analisa-se cada radiografia e verifica-se na região segmentada da imagem *Idet* se esta corresponde a um defeito real (bolhas de ar, que são visíveis na radiografia original apresentando-se como uma região mais “branca”) ou se corresponde a ER, como por exemplo, a região onde insere-se o pino do isolador, que pode ser

Tabela 6.1: CARACTERÍSTICAS GEOMÉTRICAS CALCULADAS PARA A IMAGEM SEGMENTADA DA FIGURA 6.8 EM  $0^0$ .

Região	$C_1$	$C_2$	$C_3$	$C_4$	$C_5$	$C_6$	$C_7$	$C_8$	$C_9$	$C_{10}$
1	68	68	170.26	252.29	12.328	7.773	0.77617	58.519	1	9.3049
2	135	135	197.58	110.02	17.291	10.235	0.806	22.716	1	13.111
3	1638	1647	234.17	154.68	58.423	42.239	0.69086	-23.92	-4	45.668
4	9	9	228	179	3.4641	3.4641	0	0	1	3.3851
5	145	145	269.15	108.19	17.499	10.783	0.7876	-0.86228	1	13.587
6	37	37	265.89	148.03	7.9137	6.1648	0.62702	50.778	1	6.8637
7	53	53	294.26	253.38	9.515	7.8801	0.56046	69.994	1	8.2147

Tabela 6.2: CARACTERÍSTICAS TOPOLÓGICAS CALCULADAS PARA A IMAGEM SEGMENTADA DA FIGURA 6.8 EM  $0^0$ .

Região	$C_{11}$	$C_{12}$	$C_{13}$
1	90.706	0.35294	0.043083
2	70.289	-0.13333	0.041522
3	77.722	-0.03602	0.1224
4	75.667	-0.33333	0.0050167
5	64.855	-0.15172	0.024752
6	72	-0.35135	0.013969
7	90.245	0.28302	-0.0048901

segmentada junto com o defeito real. Feito isso, faz-se a separação dos dados que foram indicados como D daqueles que foram indicados como ER, para em seguida formar as matriz de entrada dos classificadores (dos dados, 654 são ER e 60 são D). A rotina utilizada procura por +1 na primeira coluna para formar o conjunto de defeitos, e por -1 para formar o conjunto de estruturas regulares.

Por exemplo, nos dados da tabela 6.2 e 6.1 existem duas regiões que são defeitos reais (serão indicadas por +1). As cinco regiões restantes serão consideradas como estruturas regulares (-1).

A aprovação ou reprovação da peça pode ser tomada ao final do processo. Se o isolador acusar defeito, por menor que seja, ele deve ser rejeitado.

## Capítulo 7

# RESULTADOS E DISCUSSÕES

### 7.1 DETERMINAÇÃO DO COEFICIENTE DE ATENUAÇÃO LINEAR DO POLIETILENO DE ALTA DENSIDADE

Os isoladores poliméricos em geral são confeccionados em polietileno de alta densidade (HDPE). Cada fabricante utiliza uma composição particular. É comum a adição de cargas ao material com o objetivo de otimizar as propriedades elétricas, térmicas e mecânicas, ou seja, o isolador pode não conter somente HDPE. Como o coeficiente de atenuação linear do material de que é composto o isolador não está referenciado em nenhuma bibliografia e sabendo-se que esta informação é importante, principalmente porque orienta na composição do ensaio radiográfico (energia no tubo, limitações quanto à espessura da amostra, etc), torna-se necessária a determinação deste coeficiente.




Figura 7.1: Modelo utilizado para a determinação do coeficiente de absorção linear do HDPE.

Com esse intuito, confeccionou-se uma amostra em forma de escada (ver figura 7.1) com material retirado de um isolador (fabricante E). Em seguida adquiriu-se as radiografias digitais do modelo, conforme mostram as figuras 7.2a e 7.2b, respectivamente. As radiografias foram tiradas de forma que o caminho percorrido pelo raio X fosse diferente em cada degrau da “escada”.




Figura 7.2: Radiografia digital da amostra de HDPE em forma de escada. As setas indicam o caminho para o perfil obtido: (a) SISTEMA CT2000 (110 kV, 5 mA, fator de zoom 4) e em (b) SISTEMA RDP (70 kV, 100  $\mu$ A, fator de integração 5 s).

As figuras 7.3a e 7.3b exibem o perfil das imagens 7.2a e 7.2b, respectivamente. Esse perfil foi traçado da esquerda para a direita nas radiografias da figura 7.2a e 7.2b, utilizando-se o comando `improfile` do *toolbox* de imagens do MATLAB e selecionando-se a região da escada de HDPE (ver seta na figura 7.2). Observando-se o perfil obtido, pode-se concluir que em 7.3a o perfil não é bem definido para regiões muito espessas do modelo, implicando em uma imagem com um contraste ruim nestas espessuras para o SISTEMA CT2000. Já para o perfil obtido da radiografia do SISTEMA RDP os degraus são melhores definidos.

Para a obtenção do coeficiente de absorção linear do HDPE, mediu-se as intensidades (valores médios de níveis de cinza) nas duas radiografias obtidas, em cada degrau da escada e plotou-se um gráfico função da distância percorrida pelo feixe. Da relação de Beer-Bauguer (equação 2.6.2), pode-se expressar a relação linear:

$$\ln \frac{I}{I_0} = -\mu x \quad (7.1.1)$$

A partir dos dados medidos para a intensidade medida nas radiografias e a distância percorrida pelo feixe de raios X pode-se plotar  $\ln(I/I_0)$  versus  $x$ , conforme sugere a equação 7.1.1 para a obtenção de  $\mu$ . Na figura 7.4 são apresentados os resultados das medidas. Pela regressão linear dos dados, determinou-se o coeficiente de atenuação linear médio do material de que é composto os isoladores pelos dois sistemas de radiografia.

O valor encontrado para o coeficiente de absorção linear médio do HDPE foi de  $0,137 \pm 0.003 \text{ cm}^{-1}$  para os dados a partir do sistema CT2000 (110 kV) e de  $0,201 \pm 0.001 \text{ cm}^{-1}$  para os dados do SISTEMA RDP (70 kV). O valor encontrado na literatura para o polietileno puro, conforme a figura 2.7 para a energia de 50 keV, por exemplo, é igual a  $0,200 \text{ cm}^{-1}$  e em 110 keV é de  $0,166 \text{ cm}^{-1}$ , considerando-se que o  $\rho$  do polietileno puro é igual a  $0,952 - 0,965 \text{ g/cm}^3$ . Essas comparações entre os valores encontrados e os valores tabelados foram feitas apenas para verificar a dimensão da medida realizada, sem indicar que o valor obtido pelo sistema RDP ou CT2000






Figura 7.3: Perfil de nível de cinza obtido através das imagens da figura 7.2: (a) SISTEMA CT2000 e do (b) SISTEMA RDP.

é melhor ou não. É importante ressaltar ainda, que os valores experimentais obtidos correspondem a médias, pois o espectro do tubo possui uma distribuição contínua de energias dos fótons.

## 7.2 LIMITE DE DETECÇÃO DOS SISTEMAS CT2000 E RDP

A resolução de baixo contraste determina qual será o menor defeito detectado pelo sistema. Como os defeitos mais comuns em isoladores poliméricos são vazios, tais como bolhas ou trincas, e estes são preenchidos com ar ou algum gás resultante de reações químicas que aparecem durante o processo de fabricação do isolador, realizou-se uma simulação para verificar o limite de detecção dos dois sistemas de radiografia citados aqui. Para isso, utilizaram-se as curvas do coeficiente de absorção linear em massa do polietileno e do ar mostradas na figura 2.7.

O contraste da imagem depende da diferença de intensidades entre dois feixes vizinhos. Sendo o primeiro que atravessa a região do defeito e emerge com intensidade  $I_d$  e o segundo que atravessa o material na região próxima ao defeito e emerge com intensidade  $I_L$  conforme ilustra a figura 7.5.

O contraste mínimo é limitado pela faixa dinâmica do detector, i.e., pela resolução que detector apresenta para detectar diferenças de intensidades. Utilizando a equação de Beer-Bauguer para determinar as intensidades, têm-se

$$I_L = I_0 e^{-\frac{\mu_m}{\rho_m} \rho_m L} \quad (7.2.1)$$

$$I_d = I_0 e^{-\frac{\mu_m}{\rho_m} \rho_m (L-d) - \frac{\mu_a}{\rho_a} \rho_a d} \quad (7.2.2)$$

onde  $I_L$  é a intensidade do feixe emergente na região próxima ao defeito,  $I_d$  é a intensidade do feixe emergente que atravessou a região do defeito,  $I_0$  é a intensidade do feixe,  $\mu_m$  é o coeficiente de absorção do material do objeto,  $\mu_a$  é o coeficiente de absorção do material do defeito,  $\rho_m$  é a massa específica do material do objeto,  $\rho_a$  é a massa específica do material do defeito,  $L$  é o comprimento total da amostra na direção do feixe de raios X e  $d$  é o comprimento do defeito na direção do feixe de raios X.

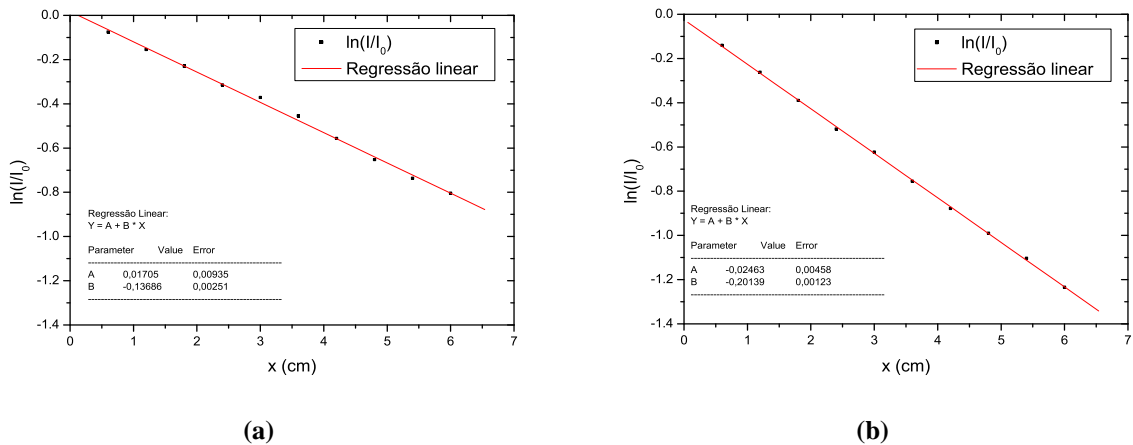


Figura 7.4: Gráficos utilizados para a determinação do coeficiente de absorção linear médio através do (a) SISTEMA CT2000 e do (b) SISTEMA RDP.




Figura 7.5: Representação dos feixes de raios X atravessando a amostra para a simulação do limite de detecção dos SISTEMAS CT2000 e RDP.

As figuras 7.6a e 7.6b mostram os resultados para a simulação da sensibilidade de um sistema de aquisição de imagens radiográficas de 8 bits (256 níveis de cinza) e 12 bits (4096 níveis de cinza) em relação ao tamanho do defeito encontrado numa amostra de polietileno.

A figura 7.7a mostra os resultados para a simulação do contraste em função do tamanho do defeito. No sistema com 4096 níveis de cinza é possível ver um grupo maior de tons de cinza que no sistema com 256 níveis (CT2000).

A figura 7.7b mostra como varia a intensidade, em unidades arbitrárias, plotada contra a espessura percorrida pelo feixe de raios X. Os pontos em preto foram simulados e os pontos obtidos para o sistema RDP e CT2000 foram obtidos lendo-se a intensidade média do nível de cinza de cada degrau da escada e após isso, normalizando estes para que ficassem entre 0 e 1. Pode-se ver nessas figuras citadas o melhor desempenho do sistema RDP em relação ao sistema CT2000.

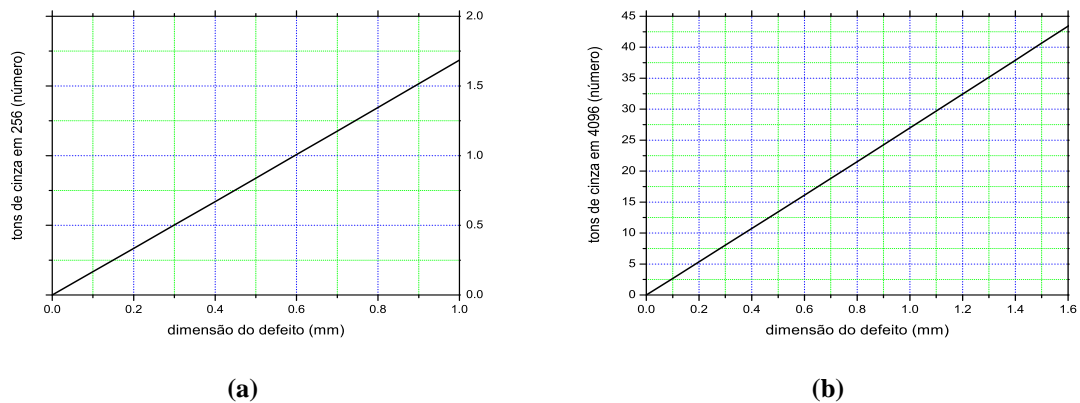


Figura 7.6: Simulação da sensibilidade do nível de cinza em função do tamanho do defeito:(a) SISTEMA CT2000 (256 níveis) (b) SISTEMA RDP (4096 níveis).

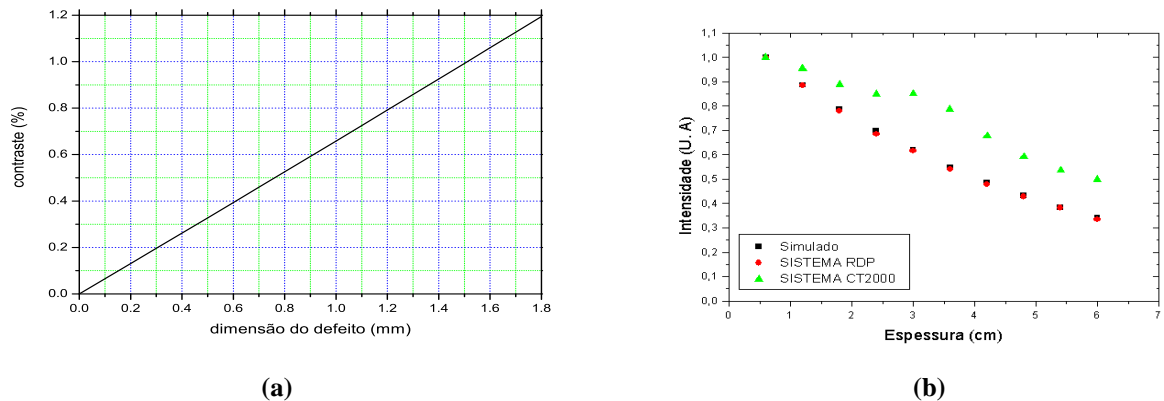


Figura 7.7: (a) Simulação realizada para o contraste da imagem em função do tamanho do defeito. (b) Intensidade *versus* espessura para os dados simulados, a partir do sistema RDP e CT2000.

### 7.3 SEGMENTAÇÃO DAS IMAGENS

O processo de segmentação é uma das etapas mais difíceis do processamento digital de imagens. Um problema encontrado durante esta etapa é o método de binarização (local) utilizado após o uso das operações morfológicas. Conforme citado no capítulo 7, utilizou-se a transformada estendida-mínima [30] para a limiarização das imagens. A operação é sensível ao valor de  $H$  nessa limiarização. Variando-se  $H$  chegou-se a um valor otimizado de 11. Conforme mostra a figura 7.9, na operação de limiarização da imagem 7.8, se  $H$  mudar, um defeito hipotético pode ou não ser detectado na segmentação. Os melhores valores para as imagens analisadas aqui ficaram entre 11 e 22. Pode-se ver que um bom valor para esta amostra é  $H = 18$ . Este método de segmentação mostrou-se bastante empírico, em uma aplicação industrial, por exemplo, um outro metodologia seria melhor aplicado, mas aqui neste trabalho de mestrado, os resultados mostraram-se satisfatórios.

O total de regiões segmentadas foi de 714 (60 regiões são defeitos reais (D) e 654 são estruturas regulares (ER)). A figura 7.10 mostra os resultados da segmentação para várias amostras utilizadas.




Figura 7.8: Imagem utilizada para estudo do valor de H.




Figura 7.9: Comparação para valores de H na operação de limiarização para a imagem da figura 7.8.

## 7.4 LEVANTAMENTO DAS CARACTERÍSTICAS

As treze características citadas no capítulo 3 foram calculadas para todas as regiões segmentadas (714 regiões). Assim, uma matriz de dados com dimensão 714 linhas por 13 colunas é definida. Esta matriz será utilizada no treinamento e teste da rede neural. A figura 7.1 ilustra o conjunto de dados obtidos que são inseridos em um arquivo ASCII formato txt.

## 7.5 CLASSIFICAÇÃO

As características calculadas foram correlacionadas entre si. A correlação entre as características foi avaliada, analisando-se o coeficiente de correlação linear, bem conhecido em estatística e calculado pela fórmula [40, 41]:

$$C(x, y) = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{\sigma_x} \right) \left( \frac{y_i - \bar{y}}{\sigma_y} \right) \quad (7.5.1)$$




Figura 7.10: Resultado da segmentação dos defeitos hipotéticos.

onde  $C(x, y)$  é a correlação linear entre as variáveis  $x$  e  $y$ ,  $\bar{x}$  e  $\bar{y}$  são os valores esperados das variáveis  $x$  e  $y$  e os valores dos desvios padrões das variáveis  $x$  e  $y$  são dados por  $\sigma_x$  e  $\sigma_y$ , respectivamente.

Para verificar a confiabilidade da correlação entre as características, utilizou-se o critério de que valores de correlação da ordem de  $2/\sqrt{N}$ , sendo  $N$  o número de amostras de cada característica/classe. A tabela 7.1 mostra a correlação linear entre as características e entre estas e as classes. A última coluna apresenta as classes. A matriz é simétrica, então basta analisar um lado e a última coluna. Pode-se ver que a primeira característica tem correlação com quase todas as outras. O limite é  $2/\sqrt{N} = 0,075$ , ou seja, valores iguais a esse de coeficiente de correlação, mostram 95% de probabilidade de ter correlação linear entre as variáveis [41].

A partir dos dados da tabela 7.1, pode-se ver que as características são muito correlatas. Duas bem mais relevantes que as outras. A primeira característica é muito correlata com a segunda, com a sexta, com a quinta e com a décima também. As características mais relevantes são as características 4, 5 e 11.




Figura 7.11: Ilustração do grupo de dados obtidos após o cálculo das características das regiões segmentadas.

A fim de verificar como é a distribuição do espaço de entradas dos dados obtidos para as características, três características mais relevantes ( $C_4$ ,  $C_5$  e  $C_{11}$ ) montou-se os dados num gráfico conforme mostra a figura 7.12 para a separação de defeito (D) e estrutura regular (ER) (as duas classes em questão). Os dados foram normalizados para que ficassem entre 1 e -1. Pode-se concluir, a partir destes gráficos, que as classes estão melhor separadas com as características 4 e 11 conforme observado na tabela 7.1. Isto é bom, pois no futuro o sistema pode ser reduzido em quantidade de características.

O gráfico da figura 7.13 mostra os componentes principais de discriminação linear (CPDL) das características levantadas. Elas foram implementá-las com uma rede neural de uma camada com função de ativação  $\tanh$  [1].

Em termos de treinamento da rede por gradiente descendente da curva de erro médio quadrático, a existência de classes de padrões com quantidades de dados desiguais pode ocasionar o favorecimento do acerto de classificação das classes com maior quantidade de amostras, já que essas tendem a influenciar mais significativamente no cálculo do erro de treinamento. Neste caso, uma solução paliativa, mas que na maioria das vezes proporciona bons resultados, é replicar os dados da classe com menor quantidade de dados até que esta atinja o número de dados da classe mais favorecida, ou seja, das estruturas regulares. Neste caso, como no trabalho dispunha-se de 654 dados de estrutura regular e 60 dados de defeito, estes últimos foram replicados até atingir 654 dados, igualando o número de amostras em cada classe.

O próximo passo na implementação dos classificadores foi a otimização do número de neurônios na

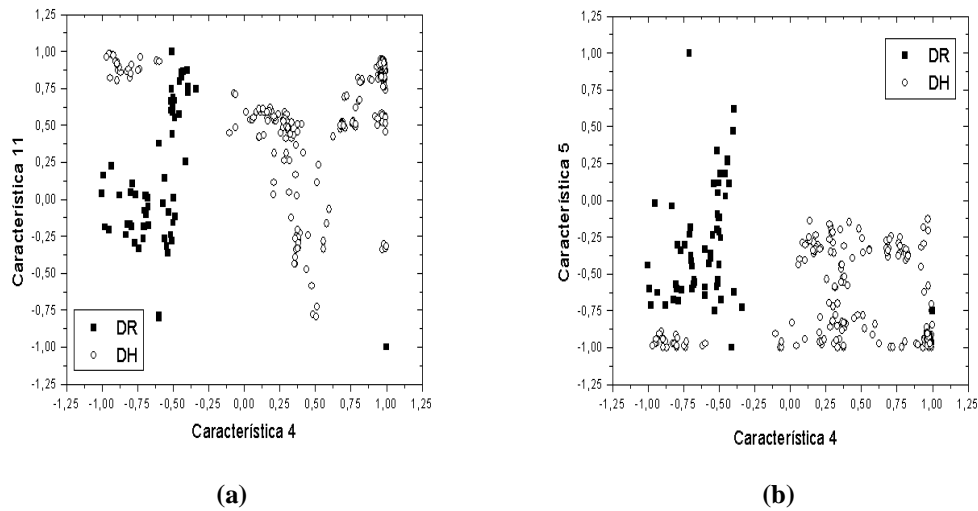


Figura 7.12: (a) Característica 11 *versus* característica 4 (b) característica 5 *versus* característica 4. Os dados foram normalizados para que ficassem entre 1 e -1.

camada intermediária da rede neural visando ao melhor resultado em termos de generalização [2]. Para tal, primeiramente sorteou-se um par de conjunto de treinamento e teste composto por respectivamente 80% e 20% dos 1308 dados existentes após a replicação. Posteriormente, variou-se o número de neurônios na camada intermediária de 1 até 15 neurônios no classificador não-linear, sendo o treinamento feito em 3000 épocas, após as quais a curva de erro se estabilizava, com utilização de taxa de aprendizado a variável e momento  $\beta = 0.1$  [2]. Os resultados de desempenho do classificador para os dados de treinamento de teste, e para cada número de neurônios na camada intermediária, são apresentados na tabela 7.2.

Pela tabela 7.2, constata-se que o melhor desempenho obtido com os dados de teste foi para 10 neurônios na camada intermediária (95, 41%). A partir deste resultado, 10 novos conjuntos foram sorteados para estimação da acurácia de classificação do classificador não-linear [1] para as classes ER e D. A metodologia de sorteio dos pares de conjuntos foi realizada de forma a garantir que nenhuma amostra sorteada para teste tivesse sido usada na estimação dos parâmetros do classificador (treinamento), tendo sido procedida da seguinte maneira: sorteou-se, aleatoriamente, 15% dos dados originais de ER (654) para conjunto de teste, resultando em 98 dados, sobrando assim 556 dados para o conjunto de treinamento. O mesmo foi feito para a classe D, neste caso 15% dos 60 dados resultaram em 9 dados para o conjunto de teste, sobrando 51 dados para treinamento. Para igualar o número de amostras/dados entre as classes, os 51 dados de treinamento de D foram replicados até atingir os 556 dados de ER, ficando o conjunto total de treinamento com 1112 dados. Para os conjuntos de testes, replicaram-se os 9 dados de D até atingir os 98 dados de teste de ER, ficando o conjunto total de teste com 196 dados. Este procedimento foi repetido 10 vezes para formar os 10 pares de conjuntos utilizados no treinamento e teste dos classificadores.

Para assegurar a generalização dos classificadores, durante os treinamentos utilizaram-se conjuntos de validação compostos por 15% de dados dos conjuntos de treinamento (do total de 1112 dados). O controle de super-treinamento dos classificadores não-lineares é normalmente feito com conjunto de validação, que serve para

Tabela 7.1: MATRIZ COM COEFICIENTES DE CORRELAÇÃO LINEAR.

	1	2	3	4	5	6	7	8	9	10	11	12	13	
	$2/\sqrt{N} = 0.075$													Classe
1	1.000	0.995	0.033	-0.035	0.776	0.951	0.019	-0.102	-0.475	0.959	-0.069	-0.037	0.394	-0.032
2	0.995	1.000	0.108	-0.032	0.795	0.966	0.118	-0.102	-0.504	0.950	-0.077	0.049	0.388	-0.033
3	0.033	0.108	1.000	-0.081	0.201	0.171	0.727	-0.053	-0.287	0.031	-0.016	0.590	0.000	0.007
4	-0.035	-0.032	-0.081	1.000	0.021	-0.047	0.037	0.016	0.064	-0.020	-0.041	0.037	-0.020	-0.280
5	0.776	0.795	0.201	0.021	1.000	0.773	0.339	-0.092	-0.202	0.872	0.347	0.284	0.534	0.057
6	0.951	0.966	0.171	-0.047	0.773	1.000	0.205	-0.112	-0.509	0.921	-0.095	0.140	0.365	0.014
7	0.019	0.118	0.727	0.037	0.339	0.205	1.000	-0.005	-0.186	0.029	-0.15	0.884	0.022	0.016
8	-0.102	-0.102	-0.053	0.016	-0.092	-0.112	-0.005	1.000	0.058	-0.106	0.060	0.004	-0.102	-0.028
9	-0.475	-0.504	-0.287	0.064	-0.202	-0.509	-0.186	0.058	1.000	-0.410	-0.078	0.110	-0.178	0.036
10	0.959	0.950	0.031	-0.020	0.872	0.921	0.029	-0.106	-0.410	1.000	-0.174	-0.064	0.478	0.049
11	-0.069	-0.077	-0.016	-0.041	-0.347	-0.095	-0.150	0.060	-0.078	-0.174	1.000	-0.120	-0.357	-0.111
12	-0.037	0.049	0.587	0.037	0.284	0.140	0.884	0.004	0.110	-0.064	-0.120	1.000	-0.084	-0.022
13	0.394	0.390	0.000	-0.020	0.534	0.365	0.022	-0.102	-0.178	0.478	-0.357	-0.084	1.000	0.029

Tabela 7.2: OTIMIZAÇÃO DO NÚMERO DE NEURÔNIOS NA CAMADA INTERMEDIÁRIA DO CLASSIFICADOR NÃO-LINEAR.

Número de Neurônios na Camada Intermediária	Treinamento (%)	Teste (%)
1	92,17	91,60
2	98,30	93,87
3	91,90	90,81
4	98,30	94,26
5	92,17	87,00
6	92,36	91,20
7	92,17	91,20
8	92,27	90,81
9	98,40	95,02
10	98,40	95,41
11	98,30	95,02
12	91,22	90,04
13	98,40	95,02
14	98,30	94,23
15	92,27	91,20






Figura 7.13: Componentes principais de discriminação linear (CPDL).

parar o treinamento quando o erro de validação se mantém estável ou cresce por um dado número de épocas que é fixado para cada caso. A média de acerto de classificação obtida com os conjuntos de teste pode ser considerada como uma estimação da acurácia de classificação [1] das classes defeito e estrutura regular. A tabela 7.3 a seguir mostra os resultados de acerto obtidos para cada par de conjuntos, assim como o número de épocas que durou o treinamento em cada situação, e também a média de acerto e o desvio padrão obtido.

Tabela 7.3: CÁLCULO DA ACURÁCIA DE CLASSIFICAÇÃO COM O CLASSIFICADOR NÃO-LINEAR. O ASTERISCO INDICA O CONJUNTO UTILIZADO PARA PLOTAR O GRÁFICO DA FIGURA 7.14a.

Conjuntos	Treinamento (%) (Dados/Acerto)	Teste (%)	Épocas
1	1112/100	195/99,50	275
2	1112/100	185/94,40	95
3	1112/100	195/99,50	181
4	1112/100	185/94,40	98
5	1112/100	196/100	118
6	1112/100	196/100	81
7*	1112/100	194/99,00*	112
8	1112/100	196/100	88
9	1112/100	185/94,40	178
10	1112/100	196/100	118
Média	100	98,12	
Desvio Padrão	0	2,60	

Pela tabela 7.3, verifica-se que a média de acerto dos conjuntos de testes foi de 98,12% o que pode ser considerada como bastante satisfatória. A generalização do classificador não-linear ficou confirmada pelas poucas diferenças existentes entre os índices de acerto de treinamento e teste. Para controle de validação, ajustou-se o treinamento para interrupção após 100 épocas, ou seja, se o erro de validação crescesse ou se mantivesse

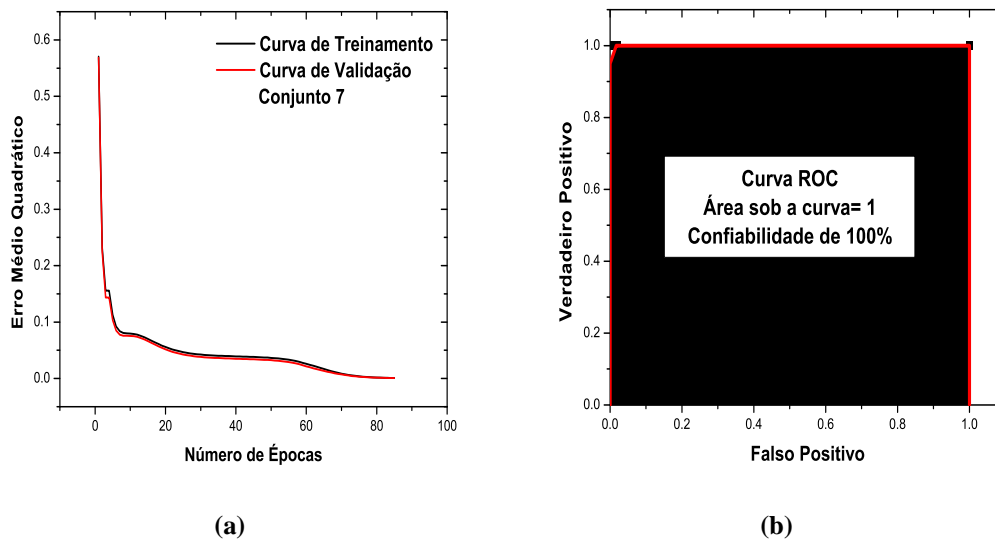


Figura 7.14: (a) Curvas de erro de treinamento e validação do conjunto 7 da tabela 7.3. (b) Curva ROC que permite o cálculo da confiabilidade de detecção de defeitos.

estável durante 100 épocas, o treinamento era interrompido. Entretanto, os treinamentos foram interrompidos por ter-se atingido primeiramente o erro mínimo fixado que foi de 0.001, dando 100% de acerto para os conjuntos de treinamento. O conjunto 7 foi aquele que apresentou um resultado mais significativo do ponto de vista de proximidade do valor da média, sendo o resultado deste conjunto usado para mostrar as curvas obtidas de erro de treinamento e teste (ver figura 7.14a).

Os índices de Falso Positivo (FP), valores de ER que foram indicados como D, e Verdadeiro Positivo (VP), valores de D corretamente indicados como D, foram calculados para cada conjunto de teste para a estimação da curva ROC (*Receiver Operating Characteristic*) [36], que pode ser utilizada como outra maneira de estimação da confiabilidade de detecção de defeito do sistema, além da média de acerto já apresentada. Os índices de FP, representados no gráfico ilustrado na figura 7.14b sobre o eixo x, são as razões entre o número de dados de ER que foram indicados pelo classificador como D sobre o número total de dados de ER em cada conjunto, neste caso de conjuntos de teste, 98. Os índices de VP, representados no gráfico ilustrado na figura 7.14b como eixo y, são as indicações corretas da classe D, número de dados de D indicados como D sobre o número total de dados dessa classe em cada conjunto de teste, como houve replicação, têm-se os mesmos 98 dados. Como houve repetição dos índices obtidos de FP e VP entre os 10 conjuntos de teste, a quantidade de pontos disponíveis para estimação da curva ROC ficou restrita a quatro pares de FP e VP: (0; 0.9), (0; 1), (0.01; 1) e (0.02; 1). O ponto (1; 1) embora não tenha sido obtido, foi introduzido apenas para facilitar a estimação da curva. A curva foi estimada fazendo-se uma interpolação de 60 pontos, número encontrado empiricamente, nos pontos de FP e VP encontrados. A área sob a curva dá a confiabilidade do sistema de detecção [37, 36]. Neste caso, calculou-se a área simplesmente como a integral da curva estimada. A tabela 7.4 mostra os valores encontrados de VP e FP, também conhecidos como *Sensibilidade e Especificidade* [37], e a figura 7.14b mostra a curva ROC estimada para o sistema de detecção de falhas em isoladores poliméricos. A área encontrada sob a curva foi igual a 1, indicando 100% de

probabilidade de detecção de defeito. Este índice é acima da acurácia estimada (cerca de 98%), mas verifica-se que os valores são bem próximos e comprobatórios da eficiência e confiabilidade dos algoritmos de processamento de imagens e classificação de defeitos implementados no presente trabalho de tese. Evidentemente que diante da pouca quantidade de dados disponíveis, principalmente da classe D, para que se tenha uma confiabilidade ainda maior do sistema, uma quantidade maior de dados deverá ser utilizada para novas análises de detecção, permitindo assim estimações ainda mais precisas da acurácia dos classificadores, assim como da curva ROC.

Tabela 7.4: CÁLCULO DOS VALORES DE FP E VP PARA OS 10 CONJUNTOS DE TESTES SORTEADOS.

Conjuntos	Falso Positivo (%)	Verdadeiro Positivo (%)
1	0	0.9
2	0	1
3	0.01	1
4	0.02	1
5	1	1

## Capítulo 8

# CONCLUSÕES

O objetivo do trabalho centrou-se na composição de um sistema de radiografia digital portátil (denominado SISTEMA RDP), o qual implicou no desenvolvimento da instrumentação eletrônica (*hardware*) e dos algoritmos (*software*), para a detecção (semi ou automática) de defeitos em isoladores poliméricos da classe 15 kV utilizados em linhas de distribuição de energia elétrica, com a possibilidade de aplicação deste sistema tanto no campo de trabalho do isolador (análise no poste) quanto na linha de produção do mesmo.

A motivação para esta dissertação de mestrado está numa das principais causas de falha dos isoladores poliméricos utilizados em redes de distribuição de energia elétrica: a existência de defeitos.

Assim, comenta-se nos parágrafos seguintes o que foi realizado e as conclusões desta dissertação.

Determinou-se o coeficiente de absorção do material de que é composto os isoladores (HDPE) através do sistema CT2000 e RDP. Os valores obtidos foram  $0,137 \pm 0,003 \text{ cm}^{-1}$  para os dados a partir do sistema CT2000 (110 kV) e de  $0,201 \pm 0,001 \text{ cm}^{-1}$  para os dados do SISTEMA RDP (70 kV).

Obteve-se algumas características, quanto ao limite de detecção e sensibilidade na presença de um defeito, dos sistemas CT2000 e RDP. O sistema RDP apresentou melhores resultados do que o sistema CT2000.

Utilizou-se 52 amostras de isoladores de diferentes fabricantes (5 tipos de amostras) para aplicar as técnicas de PDIR.

De cada amostra, 4 radiografias foram obtidas com o SISTEMA CT2000 em diferentes ângulos obtendo-se 208 imagens. O número de regiões segmentadas coorespondeu a 714. Após inspeção visual humana, a partir da radiografias obtidas, verificou-se que dessas regiões, 60 eram defeitos reais (D) e 654 estruturas regulares (ER).

Os algoritmos de segmentação com base em *pixels* de alto gradiente apresentaram-se como ótima ferramenta na detecção da ROI nas imagens radiográficas dos isoladores. Estes algoritmos apresentaram bons resultados nos diferentes tipos de amostras e nas diferentes posições das radiografias obtidas.

As operações morfológicas (*tophat* e *bottomhat*) apontam como ótimas ferramentas de segmentação de defeitos hipotéticos em imagens radiográficas de isoladores poliméricos.

Verificou-se que a transformada estendida-mínima, que é um tipo de limiarização local, é bastante sensível ao valor de H nas radiografias analisadas. O valor ajustado para as segmentações das imagens radiográficas de isoladores apontou como dois valores otimizados (H=11 e H=18). O valor adotado aqui foi H=11

A matriz com os coeficientes de correlação linear mostraram que das características calculadas, as mais relevantes são a  $C_4$  (Centróide em y),  $C_5$  (comprimento do maior eixo da região) e a  $C_{11}$  (média dos níveis de cinza da região).

Os resultados obtidos para o reconhecimento de padrões nas imagens radiográficas dos isoladores são bastante motivadores: verificou-se que existe uma separação linear do hiperplano de entrada dos dados na rede, ou seja, as classes são separáveis; constatou-se que o melhor desempenho obtido para os dados de teste na rede neural foi para 10 neurônios na camada intermediária; a média de acerto dos conjuntos de testes foi de 98,12%, que pode ser considerada como bastante boa; um excelente resultado foi obtido para os dados de testes. A curva ROC, que pode ser utilizada para a estimação da confiabilidade da detecção além da média, indicou 100% de acerto para a detecção de defeitos no sistema.

O SISTEMA RDP foi montado utilizando-se uma instrumentação dedicada para favorecer a sua portabilidade, ou seja, permitir o uso deste no campo. Este apresentou uma resolução nas imagens obtidas melhor que a do SISTEMA CT2000.

Os resultados desta dissertação motivam tanto a utilização das metodologias desenvolvidas serem aplicadas no campo de trabalho dos isoladores (linhas de distribuição), quanto seu uso em indústrias (linhas de produção dos componentes).

## 8.1 SUGESTÕES PARA TRABALHOS FUTUROS

Sugere-se para trabalhos futuros:

- Construção de uma esteira, simulando uma linha de produção estilo rejeita/aprova peça, utilizando o SISTEMA RDP e as técnicas de detecção automática dos defeitos com os métodos desenvolvidos aqui.
- Aquisição de maior número de radiografias de isoladores com defeitos reais para testar os métodos de classificação.
- Testes com *phantoms* de mamografia para um possível projeto na área médica utilizando o Sistema RDP.
- Implementação de um *software* de tomografia para o Sistema RDP com o uso da mesa rotatória do Sistema CT2000.

# Referências Bibliográficas

- [1] SILVA, R. R. *Reconhecimento de Padrões de Defeitos de Soldagem em Radiografias Industriais*, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, 2003.
- [2] HAYKIN, S. *Redes Neurais - Princípios e Prática*. Trad. Paulo Martins Engel, 2 ed., Bookman, Porto Alegre, 2001.
- [3] HACKAM, R. *Outdoor HV Composite Polymeric Insulators*. In: IEEE Trans. on Dielectrics and Electrical Insulation, vol. 6, No 5, pp 557-585, 1999.
- [4] AGERGS-RS. Disponível em <http://www.agergs.rs.gov.br/indica/indiqua1.htm>. Acesso em 13/09/2004.
- [5] EISBERG, R. and RESNICK, R. *Física Quântica*, Capítulo 2, 4a edição, editora Campus, Rio de Janeiro, 1988.
- [6] JOHNS, H. E. and CUNNINGHAM, J. R. *The Physics of Radiology*, chapter 8, Charles & Thomas Publisher, 4th edition, 1983.
- [7] SHUNG, K. K., SMITH, M. B. and TSUI, B. M. W. *Principles of Medical Imaging*, chapter 1, Academic Press Inc, 1992.
- [8] HALLIDAY, D., RESNICK, R. e WALKER, J. *Fundamentos de Física: Óptica e Física Moderna* capítulo 39, 6a edição, editora LTC, Rio de Janeiro, 2003.
- [9] X-Ray Crystallography Disponível em <http://www.tulane.edu/~sanelson/eens211/x-ray.htm>. Acesso em 31/01/2005.
- [10] Conceitos Elementares de Raios X. Disponível em <http://www.if.ufrgs.br/tex/fis142/raiosx/rxconc.html>. Acesso em 31/01/2005.
- [11] MAZZILLI, B. P. *et al* *Noções Básicas de Segurança Radiológica*. Apostila do Instituto de Pesquisas Energéticas e Nucleares - IPEN, 2002.
- [12] NIST. Disponível em <http://physics.nist.gov/PhysRefData/XrayMassCoef/ComTab/polyethylene.html>. Acesso em 22/10/2004.

- [13] Canal Ciência. Disponível em [http://www.canalciencia.ibict.br/pesquisas/pesquisa.php?ref\\_pesquisa=161](http://www.canalciencia.ibict.br/pesquisas/pesquisa.php?ref_pesquisa=161). Acesso em 09/08/2004.
- [14] ANTONAKIOS, M., LAPOUGE, V., RIZO, Ph. *CCD Based High Energy Large Field X-ray Digital Radiographic System*. In: 15th World Conference on Non-Destructive Testing, Rome, 2000.
- [15] GILES, C., HÖNNICKE, M. G., LOPES, R. T., ROCHA, H. S., GONÇALVES, O. D., MAZZARO, I., CUSATIS, C. *First Experiments on Diffraction-Enhanced Imaging at LNLS*, J. Synchrotron Radiation, v. 10, pp 421-423, 2003.
- [16] HALMSHAW, R. *Industrial Radiography: Theory and practice*, Chapman and Hall, London, 1995.
- [17] RADIOGRAPHIC INSPECTION. Disponível em <http://octarine.adfa.edu.au:8080/~kks/NDI/chap6-rad.rtf>. Acesso em 05/04/2004.
- [18] HOLST, G. C. *CCD Arrays, Cameras and Displays* 2nd Edition, JCD Publishing, 1998.
- [19] MERY, D. *Processing Digital X-Ray Images and its Application in the Automated Visual Inspection of Aluminum Castings*, 3er Panamerican Conference for Nondestructive Testing - PANNDT, Rio de Janeiro, 2003.
- [20] GONZALEZ, R. C. and WOODS, R.E. *Digital Image Processing*, Addison-Wesley Publishing Company, New York, 1992.
- [21] MERY, D. *Processing Digital X-Ray Images and its Application in the Automated Visual Inspection of Aluminum Castings*. In: 3er Panamerican Conference for Nondestructive Testing - PANNDT, Rio de Janeiro, 2003.
- [22] MERY, D., FILBERT, D. *Automated Flaw Detection in Aluminum Castings Based on the Tracking of Potential Defects in Radioscopic Image Sequence*. In: IEEE Trans. Robotics and Automation, 18(6), pp 890-901, 2002.
- [23] MERY, D., FILBERT, D. *Classification of Potential Defects in the Automatic Inspection of Aluminium Castings Using Statistical Pattern Recognition*. Disponível em: <http://www.ndt.net/article/ecndt02/232/232.htm>. Acesso em 30/01/2004.
- [24] MERY, D. *Crossing Line Profile: A New Approach to Detecting Defects in Aluminium Die Casting*, In: SCIA, LNCS 2749, pp 725-732, Berlin, 2003.
- [25] GONZALEZ, R. C. and WINTZ, P. *Digital Image Processing*, Addison-Wesley Publishing Company, Inc., 1977.
- [26] QUOIRIN, N. S. R. *Diagnóstico de Defeitos em Madeira por Tomografia de Raios X*, Dissertação de Mestrado, Universidade Federal do Paraná, Curitiba, 2004.
- [27] FACON, J. *Morfologia Matemática: Teoria e Exemplos*. Impresso na Ed. Univ. Champagnat da PUC, PUCPR, Curitiba, 1996.

- [28] Dicionário ONLINE. Disponível em <http://www.portugues.com.br/morfologia/morfolo.asp>. Acesso em 26/05/2004.
- [29] SERRA, J. *Image Analysis and Mathematical Morphology*. Academic Press, London, 1982.
- [30] SOILLE, P. *Morphological Image Analysis: Principles and Applications*, Springer-Verlag, pp. 170 – 171, New York, 1999.
- [31] FAUSETT, L. *Fundamentals of Neural Networks - Architectures, algorithms and applications*. Prentice Hall, New Jersey, 1994.
- [32] McCULLOCH, W. S and PITTS, W. *A Logical Calculus of the Ideas Immanent in Nervous Activity*. Bulletin of Mathematical Biophysics, vol 5, 1943.
- [33] ZELENOVSKY, R e MENDONÇA, A. *PC Um Guia Prático: Hardware e Interfaceamento*, Capítulo 13, Segunda Edição, MZ Editora, Rio de Janeiro, 1999.
- [34] FREW, E., HUSTER, A., LeMASTER, E. *Vision Project - CS223B - Winter 97*. Disponível em <http://sun-valley.stanford.edu/projects/helicopters/matlab.html>. Acesso em 26/03/2004.
- [35] GUREWICH, N. and GUREWICH, O. *Teach Yourself Visual Basic 5® in 21 Days*, Fourth Edition, Sams Publishing, Indiana, 1997.
- [36] DUDA, R.O., HART, P.E., STORK, D.G., *Pattern Classification*, 2nd edition, USA, John Wiley & Sons, New York, 2001.
- [37] EAGAN, J., *Signal Detection Theory and ROC Analysis*. Academic Press, New York, 1975.
- [38] OHLBACH, H. *A Resolution Calculus for Modal Logics*, In: Conference on Automated Deduction, Springer-Verlag, pp. 500 – 516, Berlin, 1988.
- [39] STERNBERG, S. R. *Parallel Architecture for Image Processing*. Proceedings of 3rd International IEEE Compsac, Chicago, 1979.
- [40] CASTLEMAN, K. *Digital Image Processing*. Oxford University Press, New York, 1996.
- [41] CHATFIELD, C. *The Analysis of Time Series – An Introduction*. Chapman and Hall, 4th edition, USA, 1989.